

Algoritmos para la estimación de parámetros de señales de tensión trifásicas distorsionadas
y desbalanceadas ante caídas de corta duración

Wilmar Alejandro Sotelo Rueda

Trabajo de Grado para Optar el título de ingeniero electricista

Director

María Alejandra Mantilla Villalobos

Doctora en ingeniería (Ing. Eléctrica, Electrónica y gestión & desarrollo)

Codirector

David Javier Rincón Adarme

Magister en ingeniería eléctrica.

Universidad Industrial de Santander

Facultad de ingenierías Fisicomecánicas

Escuela de ingenierías eléctrica, electrónica y de telecomunicaciones

Bucaramanga

2021

Dedicatoria

A mi madre

Wilmar Alejandro Sotelo Rueda

Agradecimientos

Agradezco a Dios por su infinita bondad y por todas las bendiciones que recibo de él.

Agradezco a la Universidad Industrial de Santander, Residencias Universitarias y a la escuela de ingenierías eléctrica, electrónica y de telecomunicaciones por ser parte de mi formación profesional como ingeniero.

Agradezco a la ESSA y a la Fundación Estructurar por la beca “Buena energía para tu proyecto de vida” de la cual fui beneficiado.

Agradezco a la Doctora María Alejandra Mantilla Villalobos y al Magister David Javier Rincón Adarme por su valiosa guía y ayuda para la realización de este proyecto.

Tabla de Contenido

	Pág.
Introducción	13
1. Objetivos	17
1.1 Objetivo General	17
1.2 Objetivos Específicos.....	17
2. Filtro kalman	18
2.1 Filtro Kalman Lineal	18
2.1.1 Bases del filtro Kalman.....	19
2.2 Filtro Kalman Extendido.....	20
2.3 Filtro Kalman Extendido con filtro Butterworth	22
2.3.1 Filtro Butterworth	23
2.3.2 Tensiones de entrada al filtro Butterworth.....	25
2.4 Modelo del filtro Kalman Extendido	26
2.4.1 Modelo para señales trifásicas	27
2.5 Modelo para el filtro Kalman con filtro Butterworth.....	30
3. Lazo de seguimiento de fase	32
3.1 Principio de funcionamiento de un PLL	33
3.2 sistema síncrono convencional (SRF-PLL)	36
3.3 Sistema síncrono doble desacoplado (DDSRF-PLL)	37

3.4 Modelo para sistema síncrono convencional (SRF-PLL).....	40
3.5 Modelo para sistema síncrono doble desacoplado (DDSRF-PLL).....	40
4. Filtro adaptativo – LMS.....	42
4.1 Modelo de señal trifásico propuesto para LMS	44
4.1.1 Modelo para estimación de magnitud y ángulo de fase	44
4.1.2 Modelo para estimación de frecuencia	47
5. Filtro notch adaptativo - ANF	49
5.1 Dinámica y estructura	50
5.2 Análisis de estabilidad	50
5.3 Unidad para sincronización con la red.....	51
5.4 Parámetros del filtro y condición inicial.....	52
5.5 Estructura particular para sistemas trifásicos.....	53
6. Evaluación de desempeño mediante simulación en MATLAB/SIMULINK	55
6.1 Tipos de perturbaciones	55
6.1.1 Hundimientos de tensión.....	55
6.1.2 Variaciones de frecuencia	57
6.1.3 Distorsión armónica	58
6.2 Criterios para evaluación de desempeño.....	58
6.3 Escenarios de simulación.....	60
6.4 Resultados de simulación.....	64

6.4.1 Simulación Kalman Extendido con filtro Butterworth	64
6.4.2 Simulación DDSRF-PLL	73
6.4.3 Simulación LMS	81
6.4.4 Simulación ANF	90
6.5 Análisis de resultados	98
7. Conclusiones	105
Referencias bibliográficas.....	108

Lista de Tablas

	Pág.
Tabla 1 . <i>Parámetros hundimiento de tensión primer Escenario</i>	61
Tabla 2. <i>Parámetros de simulación</i>	64
Tabla 3. <i>Resultados de simulación para los parámetros de la componente fundamental</i>	99
Tabla 4. <i>Análisis comparativo de los algoritmos</i>	101

Lista de Figuras

	Pág.
Figura 1. <i>Algoritmo recursivo del Kalman</i>	20
Figura 2. <i>Algoritmo recursivo del Kalman – Extendido</i>	21
Figura 3. <i>Filtro adaptativo Butterworth –Kalman (AB-EKF).</i>	22
Figura 4. <i>Respuesta en frecuencia del filtro Butterworth de tercer orden.</i>	24
Figura 5. <i>Estructura básica de un PLL</i>	33
Figura 6. <i>Estructura de control de un PLL básico.</i>	34
Figura 7. <i>Topología de un SRF-PLL</i>	36
Figura 8. <i>Estructura final del DDSRF-PLL</i>	39
Figura 9. <i>Esquema del filtro adaptativo</i>	43
Figura 10. <i>Esquema LMS trifásico.</i>	49
Figura 11. <i>Estructura del ANF.</i>	52
Figura 12. <i>Esquema ANF trifásico con componentes de secuencia.</i>	54
Figura 13. <i>Hundimiento de tensión ilustrativo</i>	57
Figura 14. <i>Curva ilustrativa de los criterios de desempeño.</i>	60
Figura 15. <i>Tensión trifásica del escenario 1</i>	61
Figura 16. <i>Curva de requisito LVRT de (Rodríguez et al, 2018)</i>	62
Figura 17. <i>Tensión trifásica del escenario 4.</i>	63
Figura 18. <i>Magnitud de las componentes de secuencia – Kalman</i>	65
Figura 19. <i>Frecuencia estimada – Kalman.</i>	65
Figura 20. <i>Argumento estimado por el filtro Kalman y error del argumento.</i>	66
Figura 21. <i>Magnitud de las componentes de secuencia – Kalman</i>	67

Figura 22. <i>Frecuencia estimada – Kalman</i>	68
Figura 23. <i>Estimación del argumento y el error – Kalman</i>	69
Figura 24. <i>Magnitud de las componentes de secuencia - Kalman</i>	70
Figura 25. <i>Frecuencia estimada – Kalman</i>	70
Figura 26. <i>Estimación del argumento y el error - Kalman</i>	71
Figura 27. <i>Magnitud de las componentes de secuencia – Kalman</i>	72
Figura 28. <i>Frecuencia estimada – Kalman</i>	72
Figura 29. <i>Estimación del argumento y el error – Kalman</i>	73
Figura 30. <i>Magnitud de las componentes de secuencia - DDSRF-PLL</i>	74
Figura 31. <i>Estimación de la frecuencia - DDSRF-PLL</i>	74
Figura 32. <i>Estimación del argumento y el error – DDSRF-PLL</i>	75
Figura 33. <i>Estimación de las componentes de secuencia - DDSRF-PLL</i>	76
Figura 34. <i>Frecuencia estimada - DDSRF-PLL</i>	76
Figura 35. <i>Estimación del argumento y el error – DDSRF-PLL</i>	77
Figura 36. <i>Magnitud de las componentes de secuencia - DDSRF-PLL</i>	78
Figura 37. <i>Frecuencia estimada - DDSRF-PLL</i>	78
Figura 38. <i>Estimación del argumento y el error – DDSRF-PLL</i>	79
Figura 39. <i>Estimación de la magnitud de las componentes de secuencia - DDSRF-PLL</i>	80
Figura 40. <i>Frecuencia estimada - DDSRF-PLL</i>	80
Figura 41. <i>Estimación del argumento de la componente fundamental - DDSRF-PLL</i>	81
Figura 42. <i>Magnitud de las componentes de secuencia – LMS</i>	82
Figura 43. <i>Frecuencia fundamental estimada – LMS</i>	83
Figura 44. <i>Ángulo de fase de la componente fundamental – LMS</i>	83

Figura 45. <i>Magnitud de las componentes de secuencia – LMS</i>	84
Figura 46. <i>Frecuencia fundamental estimada – LMS</i>	85
Figura 47. <i>Ángulo de fase de la componente fundamental – LMS</i>	85
Figura 48. <i>Magnitud de las componentes de secuencia – LMS</i>	86
Figura 49. <i>Frecuencia estimada – LMS</i>	87
Figura 50. <i>Ángulo de fase de la componente fundamental – LMS</i>	87
Figura 51. <i>Magnitud de las componentes de secuencia – LMS</i>	88
Figura 52. <i>Frecuencia estimada – LMS</i>	89
Figura 53. <i>Ángulo de fase de la componente fundamental – LMS</i>	89
Figura 54. <i>Magnitud de las componentes de secuencia – ANF</i>	90
Figura 55. <i>Frecuencia fundamental estimada – ANF</i>	91
Figura 56. <i>Argumento de la componente fundamental y su error de estimación – ANF</i> ..	92
Figura 57. <i>Magnitud de las componentes de secuencia – ANF</i>	93
Figura 58. <i>Frecuencia estimada – ANF</i>	93
Figura 59. <i>Argumento de la componente fundamental y su error – ANF</i>	94
Figura 60. <i>Magnitud de las componentes de secuencia – ANF</i>	95
Figura 61. <i>Frecuencia fundamental estimada – ANF</i>	95
Figura 62. <i>Argumento de la componente fundamental – ANF</i>	96
Figura 63. <i>Magnitud de las componentes de secuencia – ANF</i>	97
Figura 64. <i>Frecuencia fundamental estimada – ANF</i>	97
Figura 65. <i>Argumento de la componente fundamental – ANF</i>	98

Resumen

Título: “Algoritmos para la estimación de parámetros de señales de tensión trifásicas distorsionas y desbalanceadas ante caídas de corta duración”^{*}

Autor: Wilmar Alejandro Sotelo Rueda^{**}

Palabras Clave: Filtro Kalman extendido, filtro de mínimos cuadrados estándar (LMS), lazos de seguimiento de fase (PLL), filtros notch adaptativos (ANF).

Descripción: En la actualidad existen sistemas fotovoltaicos que incorporan funciones avanzadas de control de potencia activa y reactiva ante la ocurrencia de hundimientos de tensión de corta duración. Estos sistemas emplean inversores de potencia cuya etapa de control necesita de algoritmos de sincronización rápidos y eficaces que permitan la estimación de los parámetros de la tensión en el punto de conexión común ante estas perturbaciones. De acuerdo con lo anterior, en este trabajo de grado se presenta el análisis, simulación y comparación de los siguientes algoritmos: el filtro Kalman extendido con filtro Butterworth, el lazo de seguimiento de fase con doble sistema de referencia síncrono desacoplado (DDSRF-PLL), el filtro de mínimos cuadrados estándar (LMS), y el filtro notch adaptativo (ANF); empleados para la estimación en tiempo real de los parámetros (componentes de secuencia, frecuencia, amplitud, y fase de la componente fundamental) de señales de tensión trifásicas ante diferentes eventos de hundimientos de corta duración. Se presenta un análisis comparativo mediante simulaciones en MATLAB/SIMULINK de las características de desempeño de los algoritmos de sincronización (velocidad de convergencia, estabilidad, exactitud y robustez) en la estimación de dichos parámetros. Finalmente se formulan algunas conclusiones en términos del análisis de los algoritmos y de los resultados de simulación, y se proponen algunos trabajos futuros.

^{*} Trabajo de Grado

^{**} Facultad de ingenierías Fisicomecánicas. Escuela de ingenierías eléctrica, electrónica y de telecomunicaciones. Director: María Alejandra Mantilla Villalobos. Doctora en ingeniería. Codirector: David Javier Rincón Adarme. Magister en ingeniería eléctrica

Abstract

Title: “Algorithms for parameter estimation of distorted and unbalanced three-phase voltages under short-duration sags”.*

Author: Wilmar Alejandro Sotelo Rueda **

Key Words: Extended Kalman filter, Butterworth filter, Least Mean Square (LMS) filter, Phase Locked Loop (PLL), Adaptative Notch filter (ANF).

Description: Nowadays, there are photovoltaic systems that incorporate advanced features of active and reactive power control under short-term voltage sags. These systems use power inverters whose-control stage requires fast and efficient synchronization algorithms to estimate the parameters of the voltage at the point of common coupling under these disturbances. According to the above, this degree work presents the analysis, simulation, and comparison of the following algorithms: the filter extended Kalman with Butterworth filter, the Double Decoupled Synchronous Reference System Phase-Locked Loop (DDSRF-PLL), the standard Least Mean Squares (LMS) filter, and the Adaptative Notch filter (ANF). These algorithms are used; to estimate in the real-time the parameters (sequence components, frequency, amplitude, and phase of the fundamental component) of three-phase voltage signals under different events of short-duration drops. A comparative analysis is presented through simulations in MATLAB/SIMULINK of the performance characteristics (speed of convergence, stability, accuracy, and robustness) for the synchronization algorithms in the estimation of these parameters. Finally, some conclusions are formulated on the analysis of the algorithms and the simulation results, and some future works are proposed.

* Degree work

**Faculty of Physics Mechanical engineering. School of Electrical Engineering, Electronics and Telecommunications. Director: María Alejandra Mantilla Villalobos. PhD in Engineering. Codirector: David Javier Rincón Adarme. MSc in Electrical Engineering.

Introducción

Los operadores de red de energía eléctrica tienen el compromiso de brindar a sus clientes un suministro de energía confiable y de alta calidad. No obstante, los distintos tipos de usuarios introducen en la red de distribución cargas de tipo electrónico para la automatización de sus procesos, gestión de información, comunicaciones, entre otras, que mejoran la eficiencia de sus procesos, pero causan en la red perturbaciones que afectan la calidad de la energía y el desempeño en los sistemas de distribución (N.G. Hingorani, 1995).

Adicionalmente, en la actualidad la demanda no es la única que afecta la calidad de la energía, la generación distribuida ha tomado un protagonismo durante la última década a nivel internacional debido a la presencia de energías renovables en los sistemas de distribución. Una de estas es la generación de electricidad a partir de energía solar por medio de sistemas fotovoltaicos, los cuales han presentado un crecimiento record en los últimos años pasando de una potencia total de 8 [GW] en el 2007 a más de 705 [GW] en el 2019 (REN21, 2020). En el mercado global, la mayor proporción de energía solar fotovoltaica corresponde a sistemas conectados a la red (Bae and Kim, Sept. 2013).

Debido a la alta penetración de los sistemas fotovoltaicos en la red estos pueden traer consigo efectos secundarios como hundimientos o elevaciones de tensión, armónicos, transitorios de tipo impulso y oscilatorios, variaciones de frecuencia, ruido, entre otras, que perturban el sistema de distribución en lo que respecta a la estabilidad, la confiabilidad y la calidad de la energía (Yang et al, 2016). Justamente este trabajo de grado aborda específicamente la temática relacionada con hundimientos de tensión, los cuales también son causados por la conexión y

desconexión de cargas de gran capacidad, fallas en el sistema de distribución, maniobras en la operación, arranque de motores de gran potencia, entre otros.

Para poder describir adecuadamente las señales de tensión y/o corriente que presentan este tipo de perturbaciones, en algunas aplicaciones se emplean algoritmos de sincronización que estiman parámetros de interés como magnitud, frecuencia, ángulo de fase y componentes de secuencia entre otros (Bollen and Yu-Hua Gu, 2006).

Los algoritmos de sincronización son ampliamente utilizados en los sistemas de control de los inversores fotovoltaicos. Estos sirven para estimar el comportamiento de algunos parámetros de las señales de tensión en el punto de acoplamiento común del sistema de distribución. Así mismo, los sistemas fotovoltaicos que integran múltiples funcionalidades y mayores flexibilidades de control tienen la capacidad de operar ante fallas de corta duración en la red, para lo cual se requieren algoritmos de sincronización rápidos y eficaces que permitan la estimación de los parámetros de las señales de tensión ante estos eventos (Yang et al, 2016).

Entre las diversas técnicas de estimación en tiempo real de parámetros de señales eléctricas, se encuentran: algoritmos basados en la transformada discreta de Fourier (DFT-Discrete Fourier Transform), los cuales, operan en el dominio de la frecuencia y por lo tanto requieren la reconstrucción de la señal en el tiempo (Duarte, 2004). Por otra parte, existen algoritmos de sincronización, los cuales pueden trabajar directamente en el dominio del tiempo realizando cálculos instantáneos de los parámetros de las señales de tensión y corriente (Haykin, 2002).

En ese orden de ideas, en este trabajo se presenta un análisis, la simulación y la comparación de los siguientes algoritmos de sincronización en el dominio del tiempo: Algoritmo extendido de Kalman con filtro Butterworth, el DDSRF-PLL (Phase-locked loop), el LMS (Least Mean Square) y filtro notch adaptativo, para la estimación en tiempo real de componentes de

secuencia, frecuencia, amplitud y argumento de la componente fundamental de señales de tensión trifásicas, ante diferentes tipos de perturbación que existen en la red.

Este trabajo de grado se estructura de la siguiente manera:

El capítulo 1 se presenta una introducción en la cual se describe el marco teórico en el que están inmersos los algoritmos de sincronización y algunas de sus aplicaciones en sistemas de energía eléctrica.

En el capítulo 2 se presentan las bases teóricas del filtro Kalman, luego se describe el algoritmo Kalman extendido y el mismo incorporando un filtro Butterworth. Asimismo, se el modelo de señal empleado para la estimación de los parámetros de la componente fundamental para cada uno de ellos.

En el capítulo 3, se muestra el principio de funcionamiento del algoritmo PLL, el análisis de los algoritmos SRF-PLL y DDSRF-PLL, los filtros empleados y el modelo de señal para cada uno de ellos.

En el capítulo 4, se exponen las bases matemáticas genéricas del filtro LMS, después se presenta una propuesta integrada del modelo de señal para la estimación de magnitud y ángulo de fase para las componentes de secuencia y un modelo de señal para la estimación de la frecuencia.

En el capítulo 5, se presenta un filtro notch adaptativo modificado de ecuaciones no lineales, su estructura y el análisis matemático para obtener los parámetros de señal de la componente fundamental.

En el capítulo 6 se presenta la definición de los tipos de perturbación en la señal de tensión estudiados en este trabajo uno de ellos los hundimientos de tensión, los criterios para evaluación de desempeño de los algoritmos, los escenarios de prueba, los resultados de simulación para cada uno de los algoritmos ante los escenarios de prueba. También se muestra un análisis de resultados

en el cual se presentan los datos numéricos para los criterios de evaluación y a partir de estos un análisis comparativo cualitativo de cada uno de los algoritmos para los diferentes tipos de perturbaciones escogidos en los escenarios de prueba.

Finalmente, en el capítulo 7 se presentan las conclusiones a partir de los resultados de simulación y también de la comparación de los criterios de desempeño que son definidos en la sección 6.3. Por otra parte, se presentan los trabajos futuros en los cuales se puede seguir mejorando algoritmos de sincronización como el LMS.

1. Objetivos

1.1 Objetivo General

Simular y evaluar el desempeño de algoritmos para la estimación de componentes de secuencia, frecuencia, amplitud y fase de la componente fundamental de señales de tensión trifásicas distorsionadas y desbalanceadas ante caídas de corta duración de la misma. Se considerarán algoritmos típicamente empleados en la sincronización de sistemas fotovoltaicos conectados a la red con capacidades de operación ante fallas (LVRT, por sus siglas en inglés).

1.2 Objetivos Específicos

Para garantizar el cumplimiento del objetivo general se plantean los siguientes:

- Seleccionar diferentes algoritmos de sincronización para la estimación de los parámetros de señales de tensión trifásicas distorsionadas y desbalanceadas ante caídas de corta duración.
- Realizar la simulación en MATLAB/SIMULINK de los algoritmos de sincronización seleccionados.
- Evaluar el tiempo de respuesta y el desempeño de los algoritmos de sincronización para diferentes escenarios de caídas de corta duración en las señales de tensión de entrada.

2. Filtro Kalman

Las bases matemáticas del filtro Kalman fueron dadas en el año 1960 por Rudolph E. Kalman (Kalman, 1960), quien estableció una solución al problema de filtrado lineal. Este filtro es considerado un estimador óptimo en el sentido que minimiza la covarianza del error de la estimación bajo ciertas consideraciones. El filtro de Kalman es un algoritmo recursivo que presenta una solución al problema de estimar los estados de un sistema en tiempo discreto a partir de medidas relacionadas con los estados de dicho sistema. Tanto el sistema como las medidas relacionadas con los estados pueden estar contaminadas de ruido blanco gaussiano (Petit, 2007) y (Welch y Bishop, 2001).

2.1 Filtro Kalman Lineal

A continuación, se presentan las ecuaciones fundamentales que definen el algoritmo; la ecuación de estado y la ecuación de medida. De igual forma se presentan las demás ecuaciones que corresponden al desarrollo del método recursivo.

Ecuación de estado:

$$x(n + 1) = \mathbf{A}(n)x(n) + \mathbf{U}_1(n) \quad (1)$$

Donde $x(n + 1)$ es el vector de estados del sistema en el tiempo $(n + 1)$, $\mathbf{A}(n)$ es la matriz de transición de estados que relaciona el estado en el tiempo $n + 1$ con el estado en el instante anterior n (Diaz y Ortiz, 2010).

Ecuación de medida:

$$z(n) = \mathbf{H}(n)x(n) + \mathbf{U}_2(n) \quad (2)$$

Donde $z(n)$ es el vector de los datos de medida del sistema, y $\mathbf{H}(n)$ es la matriz de medición de los estados del sistema (Diaz y Ortiz, 2010).

Las variables $\mathbf{U}_1(n)$ y $\mathbf{U}_2(n)$ representan los ruidos blancos gaussianos asociados al sistema y a la medida, respectivamente. Estas variables aleatorias se consideran conocidas y no son dependientes una de la otra, con distribuciones de probabilidades normales (Petit, 2007) y (Welch y Bishop, 2001).

2.1.1 Bases del filtro Kalman.

El desarrollo iterativo del algoritmo Kalman lineal se presenta de la siguiente manera:

En primer lugar, se debe tener un estado inicial, usualmente supuesto $\hat{x}^-(n) = x_0$ dependiendo del tipo de sistema. Esto produce un error de estimación de estado inicial $e(n) = x(n) - \hat{x}^-(n)$, el cual tendrá una covarianza $\mathbf{P}^-(n)$ normalmente también supuesta: $\mathbf{P}^-(n) = \mathbf{P}_0$ (Diaz y Ortiz, 2010). La estimación del estado posterior se realiza al corregir con base en la medición $z(n)$, de esta forma, se obtiene el estado estimado corregido con la medición $\hat{x}(n)$ así:

$$\hat{x}(n) = \hat{x}^-(n) + \mathbf{K}(n)[z(n) - \mathbf{H}(n)\hat{x}^-(n)] \quad (3)$$

Donde $\mathbf{K}(n)$ se conoce como la ganancia de Kalman y ésta dada por:

$$\mathbf{K}(n) = \mathbf{P}^-(n)\mathbf{H}^T[\mathbf{H}(n)\mathbf{P}^-(n)\mathbf{H}^T + \mathbf{R}(n)]^{-1} \quad (4)$$

Donde $\mathbf{R}(n)$ es la matriz de covarianza del vector de ruido gaussiano $\mathbf{U}_2(n)$ en la medición. La ganancia de Kalman se calcula para minimizar la covarianza del error $\mathbf{P}(n)$ entre el estado verdadero $x(n)$ y el estado estimado corregido $\hat{x}(n)$, donde $\mathbf{I}$ es la matriz identidad, se calcula $\mathbf{P}(n)$ (Diaz y Ortiz, 2010):

$$\mathbf{P}(n) = [\mathbf{I} - \mathbf{K}(n)\mathbf{H}(n)] \mathbf{P}^-(n) \quad (5)$$

A partir de la covarianza del error estimado corregido $\mathbf{P}(n)$ y el estado estimado corregido, se calcula el siguiente estado y su respectiva covarianza del error:


$$\hat{x}^-(n) = \mathbf{A}(n)\hat{x}(n-1) \quad (6)$$

$$\mathbf{P}^-(n) = \mathbf{A}(n)\mathbf{P}(n)\mathbf{A}^T + \mathbf{Q}(n-1) \quad (7)$$

Donde $\mathbf{Q}(n)$ es la matriz de covarianza del ruido gaussiano $\mathbf{U}_1(n)$ en los estados. Así el estado estimado corregido y la proyección de la covarianza de las ecuaciones 6 y 7 sirven como insumo al algoritmo para hacer una nueva estimación del estado con la medición, y así continuando con este proceso de forma iterativa (Díaz y Ortiz, 2010).

Finalmente, la linealidad de este filtro Kalman reposa en las matrices de transición $\mathbf{A}(n)$ y de medida $\mathbf{H}(n)$. A continuación, en la Figura 1 se presenta el proceso de estimación del algoritmo Kalman recursivo anteriormente descrito.

Figura 1. Algoritmo recursivo del Kalman



2.2 Filtro Kalman Extendido

El filtro Kalman extendido (EKF, Extended Kalman Filter) es caracterizado por la función no lineal de transición de estados $\mathbf{f}(n)$ la cual corresponde a la relación no lineal entre el vector de estados en los instantes n y $n+1$ (Petit, 2007).


$$x(n+1) = f(x(n)) + U_1(n) \quad (8)$$

Se determina la matriz $F(n)$ correspondiente a la matriz jacobiana $f(n)$ dada por:

$$F(n) = \frac{\partial f(x)}{\partial x} \bigg|_{\hat{x}(n)} \quad (9)$$

De acuerdo con lo anterior, se ejecuta el algoritmo de Kalman que se presenta en la Figura 2, este algoritmo es similar al presentado en la Figura 1 pero ahora la matriz $A(n)$ lineal es reemplazada por la matriz jacobiana $f(n)$ para la proyección de la estimación de los estados y para minimizar la covarianza del error se utiliza la ecuación dada por 9.

Figura 2. Algoritmo recursivo del Kalman – Extendido



Las proyecciones necesarias para este filtro extendido se determinan de la siguiente manera:

Proyección de los estados:

$$\hat{x}^-(n) = f(\hat{x}(n-1)) \quad (10)$$

Proyección de la covarianza del error:


$$P^-(n) = F(n-1)P(n-1)F^T(n-1) + Q(n-1) \quad (11)$$

Un desarrollo similar debe ser realizado cuando la relación entre las medidas y los estados es no lineal (Petit, 2007).

2.3 Filtro Kalman Extendido con filtro Butterworth

En esta tesis se aborda un algoritmo adaptativo propuesto en (Mantilla, 2016) basado en los filtros Butterworth y Kalman extendido, el cual es llamado AB-EKF (Adaptive Butterworth – Extended Kalman Filter). Un esquema del filtro se presenta en la Figura 3.

Figura 3. *Filtro adaptativo Butterworth –Kalman (AB-EKF).*



Fuente: Adaptada de (Mantilla, 2016)

El algoritmo está compuesto por dos subsistemas. El primer subsistema corresponde a un filtro Butterworth de tercer orden. Dicho filtro es utilizado para extraer la componente fundamental de las tensiones de línea con el propósito de evitar distorsión armónica y componentes de secuencia cero como entrada para el filtro Kalman. El segundo subsistema es un EKF, el cual se encarga de estimar las componentes de secuencia positiva y negativa de las tensiones de entrada y su frecuencia.

Además, el EKF es desarrollado de tal manera que el desfase generado por el filtro Butterworth en las señales de salida (u_{abf}, u_{bcf}) sea removido de las señales estimadas por el EKF (u_a^+, u_b^+, u_c^+) esto se ve reflejado en la ecuación de medida del sistema. Finalmente, la frecuencia

estimada por el EKF es retroalimentada al filtro Butterworth con el propósito de sincronizar los subsistemas y garantizar una adecuada estimación (Mantilla, 2016).

2.3.1 Filtro Butterworth

Los filtros Butterworth son caracterizados por presentar la magnitud de su respuesta en frecuencia en la banda de paso, esto los hace atractivos para actividades prácticas. Un filtro Butterworth pasa bajas de orden N presenta una respuesta en frecuencia cuya magnitud al cuadrado sigue la siguiente ecuación (Oppenheim et al, 1997):


$$|\mathcal{B}(j\omega)|^2 = \frac{1}{1 + [(j\omega)/(j\omega_f)]^{2N}} \quad (12)$$

Donde N es el orden del filtro, y ω_c es la frecuencia de corte, que para este caso será la frecuencia angular fundamental. En la ecuación (13) se presenta la función de transferencia de un filtro Butterworth pasa bajas de tercer orden.

$$B(s) = \frac{\omega_f^3}{s^3 + 2\omega_f s^2 + 2\omega_f^2 s + \omega_f^3} \quad (13)$$

El filtro considerado en esta tesis es el presentado en (Mantilla, 2016), con una frecuencia retroalimentada por el EKF, es decir, $\omega_f = 2\pi f$ donde f es la frecuencia fundamental de la red. En la figura 4 se presenta la respuesta en frecuencia del filtro de la ecuación (13).

Figura 4. Respuesta en frecuencia del filtro Butterworth de tercer orden.



De acuerdo con la frecuencia $\omega_f = \omega = 2\pi f$, la respuesta en frecuencia en ese punto presenta una amplitud de $\frac{1}{\sqrt{2}}$ y un ángulo de fase de $-\frac{3\pi}{4}$ [rad]. De acuerdo con (Mantilla, 2016), se supone una señal de entrada al filtro ($x_B(t)$) sinusoidal de frecuencia $\omega_f = 2\pi f$. La respuesta del filtro ante esta señal está dada por la ecuación (14) (Mantilla, 2016).

$$y_B(t) = \frac{A}{\sqrt{2}} \sin\left(\omega_f t - \frac{3\pi}{4}\right) + \frac{Ae^{-t\omega_f}}{2} + \frac{2Ae^{-\frac{t\omega_f}{2}}}{\sqrt{3}} \sin\left(\frac{\sqrt{3}\omega_f t}{2}\right) \quad (14)$$

El primer término de la señal de salida $y_B(t)$ muestra la respuesta deseada de estado estable, es decir, la señal de entrada con una amplitud reducida y en desfase. Los dos términos restantes son la parte de la respuesta transitoria que se hacen cero aproximadamente en 26,5 [ms] (poco menos de dos ciclos de la señal de entrada (Mantilla, 2016)).

2.3.2 Tensiones de entrada al filtro Butterworth

Para el caso de estudio de este trabajo de grado, las señales de tensión de entrada al filtro (tensiones trifásicas desbalanceadas y/o distorsionadas) corresponden con las siguientes expresiones matemáticas:

$$v_a(t) = \sum_{h=1}^M [v_h^+ \text{sen}(\omega_h t + \varphi_h^+) + v_h^- \text{sen}(\omega_h t + \varphi_h^-) + v_h^0 \text{sen}(\omega_h t + \varphi_h^0)] \quad (15)$$

$$v_b(t) = \sum_{h=1}^M [v_h^+ \text{sen}(\omega_h t + \varphi_h^+ - 120^\circ) + v_h^- \text{sen}(\omega_h t + \varphi_h^- - 120^\circ) + v_h^0 \text{sen}(\omega_h t + \varphi_h^0)] \quad (16)$$

$$v_c(t) = \sum_{h=1}^M [v_h^+ \text{sen}(\omega_h t + \varphi_h^+ + 120^\circ) + v_h^- \text{sen}(\omega_h t + \varphi_h^- + 120^\circ) + v_h^0 \text{sen}(\omega_h t + \varphi_h^0)] \quad (17)$$

Según las ecuaciones (15) a (17), cada señal de tensión está representada por la suma de las componentes de secuencia positiva, negativa y cero de cada armónico, donde h corresponde con el orden del armónico. Así, la componente armónica a la frecuencia ω_h presenta las componentes de secuencia v_h^+, v_h^-, v_h^0 y los ángulos de fase $\varphi_h^+, \varphi_h^-, \varphi_h^0$.

El filtro Butterworth es utilizado para filtrar las tensiones de línea dadas por las ecuaciones (18) y (19). El uso de las tensiones de línea reduce las señales a filtrar y elimina las componentes de secuencia cero (Mantilla, 2016).

$$v_{ab}(t) = \sum_{h=1}^M [\sqrt{3}v_h^+ \text{sen}(\omega_h t + \varphi_h^+ + 30^\circ) + \sqrt{3}v_h^- \text{sen}(\omega_h t + \varphi_h^- - 30^\circ)] \quad (18)$$

$$v_{bc}(t) = \sum_{h=1}^M [\sqrt{3}v_h^+ \text{sen}(\omega_h t + \varphi_h^+ - 90^\circ) + \sqrt{3}v_h^- \text{sen}(\omega_h t + \varphi_h^- + 90^\circ)] \quad (19)$$

Las tensiones de línea filtradas (v_{abf}, v_{bcf}), son las entradas del EKF. Dado que la respuesta en frecuencia del filtro Butterworth afecta las señales de tensión en magnitud y fase, la

componente fundamental de las tensiones de entrada al EKF en estado estable (ya que la atenuación de armónicos no es ideal) son las siguientes:

$$v_{abf}(t) = \frac{\sqrt{3}v_1^+}{\sqrt{2}} \text{sen}(\omega_1 t + \varphi_1^+ - 105^\circ) + \frac{\sqrt{3}v_1^-}{\sqrt{2}} \text{sen}(\omega_1 t + \varphi_1^- - 165^\circ) \quad (20)$$

$$v_{bcf}(t) = \frac{\sqrt{3}v_1^+}{\sqrt{2}} \text{sen}(\omega_1 t + \varphi_1^+ + 135^\circ) + \frac{\sqrt{3}v_1^-}{\sqrt{2}} \text{sen}(\omega_1 t + \varphi_1^- - 45^\circ) \quad (21)$$

2.4 Modelo del filtro Kalman Extendido

Partiendo del modelo de una señal monofásica, para determinar el vector de estados se considera una señal de la forma:

$$x(t) = A_f \cos(\omega_f t_n + \varphi_f) \quad (22)$$

Evalutando (22) en el instante $t_n + T_s$, y considerando que la frecuencia de muestreo es conocida, se obtiene la siguiente ecuación:

$$\begin{aligned} x(t_k + T_s) = A_f \cos(\omega_f(t_n + T_s) + \varphi_f) &= A_f \cos(\omega_f t_n + \varphi_f) \cos(\omega_f T_s) - \\ &A_f \text{sen}(\omega_f t_n + \varphi_f) \text{sen}(\omega_f T_s) \end{aligned} \quad (23)$$

En la ecuación (23) se presenta que $x(t_k + T_s)$ es función de la señal misma y de la señal en cuadratura. De lo anterior se deduce que la señal en un instante de tiempo se puede obtener como la suma de la misma señal más su componente en cuadratura, así definiendo los estados x_1 y x_2 correspondiéndoles los siguientes valores en el instante n (Petit, 2007) y (Manrique y Plata, 2019):

$$\begin{aligned} x_1(t_n) &= A_f \cos(\omega_f t_n + \varphi_f) \\ x_2(t_n) &= A_f \text{sen}(\omega_f t_n + \varphi_f) \end{aligned} \quad (24)$$

Operando las ecuaciones en (24) se obtienen las expresiones para el cálculo de la amplitud y ángulo de fase para la señal que se está estimando, esto es:

$$A_f = \sqrt{x_1^2(t_n) + x_2^2(t_n)}$$

$$\tan(\omega_f t_n + \varphi_f) = \frac{x_2(t_n)}{x_1(t_n)} \quad (25)$$

Luego de determinados los estados, la expresión para la ecuación de estados futuros, está dada por:

$$\begin{pmatrix} x_1(n+1) \\ x_2(n+1) \end{pmatrix} = \begin{pmatrix} \cos(\omega_f T_s) & \sin(\omega_f T_s) \\ -\sin(\omega_f T_s) & \cos(\omega_f T_s) \end{pmatrix} \begin{pmatrix} x_1(n) \\ x_2(n) \end{pmatrix} \quad (26)$$

A partir de (26) se deduce que la matriz de transición de estados lineal es igual a:

$$\mathbf{A}(n) = \begin{pmatrix} \cos(\omega_f T_s) & \sin(\omega_f T_s) \\ -\sin(\omega_f T_s) & \cos(\omega_f T_s) \end{pmatrix} \quad (27)$$

Ahora considerando un nuevo estado para la frecuencia se quiere estimar su vector de estados. Entonces las ecuaciones de medida y de estado deben modificarse de la siguiente manera:

$$\begin{aligned} x_1(n+1) &= x_1(n)\cos(x_3(n)T_s) - x_2(n)\sin(x_3(n)T_s) \\ x_2(n+1) &= x_1(n)\sin(x_3(n)T_s) + x_2(n)\cos(x_3(n)T_s) \\ x_3(n+1) &= (1 - \epsilon)x_3(n) \end{aligned} \quad (28)$$

Donde $x_3(n)$ representa el vector de estados de la frecuencia de la señal fundamental, el parámetro ϵ es una constante muy pequeña cercana a cero que permite la estabilidad en la convergencia del algoritmo (Petit, 2007).

2.4.1 Modelo para señales trifásicas

Partiendo de lo mencionado para un modelo monofásico, se mostrará el modelo para señales trifásicas considerando componentes de secuencia. De acuerdo con Fortescue, las señales trifásicas v_a, v_b, v_c pueden ser representadas en términos de v^+, v^-, v^0 las cuales son las

componentes de secuencia positiva, negativa y cero, respectivamente. Partiendo de lo anterior, las señales pueden ser representadas en el tiempo mediante (29):

$$\begin{aligned}v_a(t) &= v_a^0(t) + v_a^+(t) + v_a^-(t) \\v_b(t) &= v_b^0(t) + v_b^+(t) + v_b^-(t) \\v_c(t) &= v_c^0(t) + v_c^+(t) + v_c^-(t)\end{aligned}\tag{29}$$

Considerando que cada componente tiene su propia componente de secuencia, se pueden expresar las ecuaciones en (29) de la siguiente manera:

$$\begin{aligned}v_a &= v^0 \cos(\theta^0) + v^+ \cos(\theta^+) + v^- \cos(\theta^-) \\v_b &= v^0 \cos(\theta^0) + v^+ \cos(\theta^+ - 120^\circ) + v^- \cos(\theta^- + 120^\circ) \\v_c &= v^0 \cos(\theta^0) + v^+ \cos(\theta^+ + 120^\circ) + v^- \cos(\theta^- - 120^\circ)\end{aligned}\tag{30}$$

Donde, $\theta^{0+-} = \omega_f t + \varphi^{0+-}$ describe la variación angular en función del tiempo para la componente de secuencia correspondiente (Manrique y Plata, 2019). Se asumen los siguientes estados:

$$\begin{aligned}x_1 &= v^+ \cos(\theta^+) \\x_2 &= v^+ \text{sen}(\theta^+) \\x_3 &= v^- \cos(\theta^-) \\x_4 &= v^- \text{sen}(\theta^-)\end{aligned}\tag{31}$$

Luego la ecuación de medida se puede establecer como:

$$z(n) = \begin{pmatrix} v_a(n) - v^0(n) \\ v_b(n) - v^0(n) \\ v_c(n) - v^0(n) \end{pmatrix}\tag{32}$$

Como la ecuación de medida está representada por las tensiones de fase en (30), al reemplazar (31) se tiene la siguiente ecuación de medida:

$$z(n) = \begin{pmatrix} 1 & 0 & 1 & 0 \\ -\frac{1}{2} & \frac{\sqrt{3}}{2} & -\frac{1}{2} & -\frac{\sqrt{3}}{2} \\ \frac{1}{2} & -\frac{\sqrt{3}}{2} & \frac{1}{2} & \frac{\sqrt{3}}{2} \\ -\frac{1}{2} & -\frac{\sqrt{3}}{2} & -\frac{1}{2} & \frac{\sqrt{3}}{2} \end{pmatrix} \begin{pmatrix} x_1(n) \\ x_2(n) \\ x_3(n) \\ x_4(n) \end{pmatrix} + \mathbf{U}_2(n) \quad (33)$$

Con el fin de facilitar el cálculo se reescribe la ecuación (2.32) en función de las tensiones de línea para evitar la componente de secuencia cero y a partir de esto obtener la matriz de medición de los estados $\mathbf{H}(n)$.

$$\text{Como: } v_a^0 = v_b^0 = v_c^0 = v^0 = \frac{v_a + v_b + v_c}{3} \quad (34)$$

$$z(n) = \begin{pmatrix} v_{ab}(n) \\ v_{bc}(n) \end{pmatrix} = \begin{pmatrix} \frac{3}{2} & -\frac{\sqrt{3}}{2} & \frac{3}{2} & \frac{\sqrt{3}}{2} \\ 0 & \sqrt{3} & 0 & -\sqrt{3} \end{pmatrix} \begin{pmatrix} x_1(n) \\ x_2(n) \\ x_3(n) \\ x_4(n) \end{pmatrix} + \mathbf{U}_2(n) \quad (35)$$

$$\mathbf{H}(n) = \begin{pmatrix} \frac{3}{2} & -\frac{\sqrt{3}}{2} & \frac{3}{2} & \frac{\sqrt{3}}{2} \\ 0 & \sqrt{3} & 0 & -\sqrt{3} \end{pmatrix} \quad (36)$$

La nueva ecuación de estados para la proyección de los mismos queda la siguiente manera:

$$\begin{pmatrix} x_1(n+1) \\ x_2(n+1) \\ x_3(n+1) \\ x_4(n+1) \end{pmatrix} = \begin{pmatrix} A & 0 \\ 0 & A \end{pmatrix} \begin{pmatrix} x_1(n) \\ x_2(n) \\ x_3(n) \\ x_4(n) \end{pmatrix} \quad (37)$$

Donde los estados x_1, x_2 corresponde a la componente de secuencia positiva, y los otros dos estados x_3, x_4 son los estados de la componente de secuencia negativa y A corresponde con la matriz de la ecuación (27). Finalmente, al considerar la frecuencia como un parámetro desconocido, se modifican las ecuaciones del filtro Kalman extendido y se tiene la función de transición de estados no lineal $\mathbf{f}(n)$, dada por:

$$\mathbf{f}(n) = \begin{pmatrix} x_1(n)\cos(x_5(n)T_s) - x_2(n)\sen(x_5(n)T_s) \\ x_1(n)\sen(x_5(n)T_s) + x_2(n)\cos(x_5(n)T_s) \\ x_3(n)\cos(x_5(n)T_s) - x_4(n)\sen(x_5(n)T_s) \\ x_3(n)\sen(x_5(n)T_s) + x_4(n)\cos(x_5(n)T_s) \\ (1 - \epsilon)x_5(n) \end{pmatrix} \quad (38)$$

y

$$\mathbf{H}(n) = \begin{pmatrix} \frac{3}{2} & -\frac{\sqrt{3}}{2} & \frac{3}{2} & \frac{\sqrt{3}}{2} & 0 \\ 0 & \sqrt{3} & 0 & -\sqrt{3} & 0 \end{pmatrix} \quad (39)$$

Ahora el vector de estados de la frecuencia corresponde con $x_5(n)$.

2.5 Modelo para el filtro Kalman con filtro Butterworth

En este trabajo se considera un filtro Kalman extendido para estimar las componentes de secuencia positiva y negativa de las señales de entrada a la frecuencia fundamental, las señales deseadas que se espera estimar siguen las siguientes expresiones matemáticas dadas por las ecuaciones (40) y (41):

$$\begin{aligned} v_a^+(t) &= v_1^+ \sen(\omega_1 t + \varphi_1^+) \\ v_b^+(t) &= v_1^+ \sen(\omega_1 t + \varphi_1^+ - 120^\circ) \\ v_c^+(t) &= v_1^+ \sen(\omega_1 t + \varphi_1^+ + 120^\circ) \end{aligned} \quad (40)$$

$$\begin{aligned} v_a^-(t) &= v_1^- \sen(\omega_1 t + \varphi_1^-) \\ v_b^-(t) &= v_1^- \sen(\omega_1 t + \varphi_1^- + 120^\circ) \\ v_c^-(t) &= v_1^- \sen(\omega_1 t + \varphi_1^- - 120^\circ) \end{aligned} \quad (41)$$

Considerando lo expuesto, se define el vector de estados:

$$x(n) = \begin{pmatrix} x_1(n) \\ x_2(n) \\ x_3(n) \\ x_4(n) \\ x_5(n) \end{pmatrix} = \begin{pmatrix} v_1^+ \text{sen}(\omega_1 t + \varphi_1^+) \\ v_1^+ \cos(\omega_1 t + \varphi_1^+) \\ v_1^- \text{sen}(\omega_1 t + \varphi_1^-) \\ v_1^- \cos(\omega_1 t + \varphi_1^-) \\ \omega_1 \end{pmatrix} \quad (42)$$

Como en el caso trifásico, los estados x_1 y x_2 corresponden a la componente de secuencia positiva v^+ , los otros dos estados x_3 y x_4 son los estados de la componente de secuencia negativa v^- . El último estado corresponde con la frecuencia fundamental de la señal de entrada. Considerando la anterior definición, se tiene la ecuación de estado del sistema dada por la ecuación (43) (Mantilla, 2016). Donde T_s , es el periodo al cual opera el algoritmo. El parámetro ϵ como se mencionó anteriormente es una constante muy pequeña cercana a cero ($\epsilon \geq 0$) que permite la estabilidad en la convergencia del algoritmo (Petit, 2007). A partir de la ecuación de estados (43), se determina la matriz jacobiana. Aplicando la ecuación (9), se obtiene la expresión de la ecuación (44).

Con respecto a la ecuación de medida del sistema, se deben considerar las expresiones matemáticas (20) y (21), ya que estas son las señales de entrada para el filtro extendido del Kalman que vienen del filtro Butterworth de tercer orden. Haciendo uso de la identidad trigonométrica (45), las tensiones de entrada del EKF son expresadas en función de los estados, de acuerdo con la ecuación de medida (46). Finalmente, las ecuaciones (43), (44) y (46) representan el modelo utilizado por el filtro Kalman extendido propuesto por (Mantilla, 2016).

$$\begin{pmatrix} x_1(n+1) \\ x_2(n+1) \\ x_3(n+1) \\ x_4(n+1) \\ x_5(n+1) \end{pmatrix} = \begin{pmatrix} x_1(n)\cos(x_5(n)T_s) + x_2(n)\text{sen}(x_5(n)T_s) \\ -x_1(n)\text{sen}(x_5(n)T_s) + x_2(n)\cos(x_5(n)T_s) \\ x_3(n)\cos(x_5(n)T_s) + x_4(n)\text{sen}(x_5(n)T_s) \\ -x_3(n)\text{sen}(x_5(n)T_s) + x_4(n)\cos(x_5(n)T_s) \\ (1-\epsilon)x_5(n) \end{pmatrix} \quad (43)$$

$$\mathbf{F} = \begin{pmatrix} \cos(x_5 T_s) & \sin(x_5 T_s) & 0 & 0 & -x_1 T_s \sin(x_5 T_s) + x_2 T_s \cos(x_5 T_s) \\ -\sin(x_5 T_s) & \cos(x_5 T_s) & 0 & 0 & -x_1 T_s \cos(x_5 T_s) - x_2 T_s \sin(x_5 T_s) \\ 0 & 0 & \cos(x_5 T_s) & \sin(x_5 T_s) & -x_3 T_s \sin(x_5 T_s) + x_4 T_s \cos(x_5 T_s) \\ 0 & 0 & -\sin(x_5 T_s) & \cos(x_5 T_s) & -x_3 T_s \cos(x_5 T_s) - x_4 T_s \sin(x_5 T_s) \\ 0 & 0 & 0 & 0 & (1 - \epsilon) \end{pmatrix} \quad (44)$$

$$\sin(\alpha + \beta) = \sin(\alpha)\cos(\beta) + \sin(\beta)\cos(\alpha) \quad (45)$$


$$\begin{pmatrix} z_1(n) \\ z_2(n) \end{pmatrix} = \begin{pmatrix} v_{abf}(n) \\ v_{bcf}(n) \end{pmatrix} = \begin{pmatrix} \frac{\sqrt{3}-3}{4} & \frac{-\sqrt{3}-3}{4} & \frac{-\sqrt{3}-3}{4} & \frac{\sqrt{3}-3}{4} & 0 \\ -\frac{\sqrt{3}}{2} & \frac{\sqrt{3}}{2} & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} & 0 \end{pmatrix} \begin{pmatrix} x_1(n) \\ x_2(n) \\ x_3(n) \\ x_4(n) \\ x_5(n) \end{pmatrix} + \mathbf{u}_2(n) \quad (46)$$

3. Lazo de seguimiento de fase

Los lazos de seguimiento de fase (PLL, Phase-locked loop) son sistemas de control que sirven como alternativa útil para estimar una señal eléctrica cuyo ángulo de fase está relacionado con el ángulo de fase de la señal de entrada, para este caso esto se logra sincronizando este sistema con la tensión trifásica de entrada. El objetivo principal del lazo es estimar la diferencia entre el ángulo de fase de la señal de entrada y la salida, de modo tal que esta diferencia en régimen permanente se haga cero.

La estructura básica del PLL se muestra en la figura 5, donde se observan los tres bloques fundamentales de este algoritmo, los cuales se definen a continuación (Serrano, 2014).

Figura 5. Estructura básica de un PLL

**El detector de fase (PD, Phase Detector):**

Este bloque representa un circuito que se encarga de entregar a la salida una señal proporcional al error entre la señal de entrada v y salida v' . El error es cero cuando las señales de entrada y salida están sincronizadas en frecuencia y fase.

Filtro de lazo (control PI, Proportional Integral):

Se encarga de filtrar el error, debe presentar características de filtro pasa bajas. Esto con el fin de que el error en régimen permanente sea igual a cero.

Oscilador de voltaje (VCO, Voltage Controller Oscillator):


Genera una señal de frecuencia o ángulo a partir de la entrada proporcionada por el filtro PI para realimentar el lazo hasta que el error entre fases del detector se haga cero en estado estable. Típicamente es un bloque integrador.

3.1 Principio de funcionamiento de un PLL

El principio básico de un PLL se basa en el control de un lazo cerrado con realimentación del ángulo de la componente fundamental de tensión del sistema a partir de la frecuencia de la red. Para obtener esto se hace un filtrado al error de los ángulos mediante el filtro de lazo, en este caso

el PI que es lo usualmente utilizado, junto con un integrador como un oscilador de tensión (Flórez y Gonzalo, 2014). En la figura 6 se puede observar la característica de control o de pequeña señal del ángulo del sistema que constituye un PLL básico, con una ganancia proporcional al error k_{pd} como detector de fase (PD), un controlador PI como filtro de lazo y un integrador con k_{vco} como oscilador de voltaje (VCO).

Figura 6. Estructura de control de un PLL básico.



La función de transferencia del filtro de lazo (control PI), está dada por la ecuación (47) donde k_p es la ganancia proporcional y T_i es el tiempo integral del controlador.

$$PI(s) = k_p \left(1 + \frac{1}{T_i s} \right) \quad (47)$$

Para un valor de $k_{pd} = k_{vco} = 1$, la función de transferencia de lazo cerrado es:

$$H(s) = \frac{k_p s + \frac{k_p}{T_i}}{s^2 + k_p s + \frac{k_p}{T_i}} \quad (48)$$

Sí se compara la ecuación (48) con la función de transferencia característica de un sistema de segundo orden dado por la ecuación (49), se tiene que:

$$H(s) = \frac{2\xi\omega_n s + \omega_n^2}{s^2 + 2\xi\omega_n s + \omega_n^2} \quad (49)$$

Por lo tanto,

$$k_p = 2\xi\omega_n \quad \text{y} \quad k_i = \frac{k_p}{T_i} = \omega_n^2 \quad (50)$$

Donde ω_n y ξ corresponde con la frecuencia natural y el factor de amortiguamiento del sistema, respectivamente, los cuales se pueden determinar a partir del tiempo de establecimiento t_e y el porcentaje de sobre-impulso (%SP) para modificar la forma de onda transitoria. El tiempo de establecimiento t_e se define como el tiempo que tiene el sistema para estabilizarse dentro de cierto porcentaje δ con respecto a la amplitud de la entrada (Flórez y Gonzalo, 2014). Tomando como criterio un porcentaje del $\pm 2\%$ se tiene que la amplitud de la respuesta transitoria sería (Flórez y Gonzalo, 2014):

$$e^{-\xi\omega_n t_e} < 0.02 \Rightarrow \xi\omega_n t_e \cong 4 \quad (51)$$

Se tiene,

$$t_e = \frac{4}{\xi\omega_n} \quad (52)$$

El porcentaje de sobrepaso (%SP) se obtiene del porcentaje del valor pico de la señal en estado transitorio con respecto al valor de la señal en estado estable. Para un sistema de segundo orden se define como:


$$(\%SP) = 100e^{-\frac{\pi\xi}{1-\xi^2}} \quad (53)$$

De acuerdo con la ecuación (53), el porcentaje de sobrepaso solo depende del factor de amortiguamiento ξ del sistema y para valores grandes del factor de amortiguamiento será más pequeño el porcentaje de sobrepaso. Por lo tanto, el valor de k_p y T_i del filtro de lazo determinan el comportamiento transitorio de la respuesta a su entrada (Flórez y Gonzalo, 2014).

3.2 sistema síncrono convencional (SRF-PLL)

En la figura 7 se muestra la topología de un algoritmo SRF-PLL para un sistema trifásico. Para el detector de fase (PD) se hace uso de la transformada de Clarke (Qasim et al, 2019) y Park (Qasim et al, 2019) invariantes en magnitud. El filtro de lazo se representa por un controlador PI, el oscilador de tensión (VCO) se representa con un integrador, y θ es el argumento de la componente fundamental de la señal de entrada (Flórez y Gonzalo, 2014).

Figura 7. Topología de un SRF-PLL



Estos bloques $[T_{\alpha\beta}]$ y $[T_{dq}]$ de transformación en los marcos de referencia cumplen la función de detección de fase (PD). Como se observa en la figura 7 la transformada de Park está sincronizada con la fase θ de salida. El propósito de esta estructura es modificar la posición angular del PLL para que la proyección del vector de tensión sobre el eje de cuadratura (q) del PLL sea cero en estado estable por medio del controlador PI modificando sus constantes proporcional e integrativa descritas en la ecuación (50). De esta manera se consigue que la proyección del vector sobre el eje directo (d) del PLL coincida con la magnitud de este, y la posición angular del PLL será la fase de la componente fundamental de la señal de tensión.

3.3 Sistema síncrono doble desacoplado (DDSRF-PLL)

Para describir el sistema de detección basado en un bucle cerrado de fase el cual trabaja con un doble sistema de referencia síncrono (DDSRF-PLL), se considerará el caso en el que se admite que la componente de secuencia negativa pueda presentar algún desfase con respecto a la positiva (Serrano, 2014). De esta forma, el vector de tensión se puede escribir como:

$$V_{\alpha\beta} = \begin{bmatrix} v_\alpha \\ v_\beta \end{bmatrix} = V^{+1} \begin{bmatrix} \cos(\omega t) \\ \sin(\omega t) \end{bmatrix} + V^{-1} \begin{bmatrix} \cos(\omega t + \varphi^{-1}) \\ \sin(\omega t + \varphi^{-1}) \end{bmatrix} \quad (54)$$

Donde se ha considerado que la referencia de fase se da en la componente de secuencia positiva. Según la ecuación (54), V^{+1} es un vector que gira en sentido contrario de las manecillas del reloj a velocidad ω , mientras que V^{-1} lo hace en sentido horario pero a la misma velocidad. Si esto es así, existe un sistema de referencia síncrono para dq^{+1} a una posición angular θ y otro para dq^{-1} a una posición angular $-\theta$, entonces existe un vector compuesto de tensión ($V = V^{+1} + V^{-1}$) sobre este doble sistema de referencia, dando lugar a las ecuaciones (56) y (58) (Serrano, 2014).

$$V_{dq^{+1}} = \begin{bmatrix} v_{d^{+1}} \\ v_{q^{+1}} \end{bmatrix} = [T_{dq^{+1}}] \begin{bmatrix} v_\alpha \\ v_\beta \end{bmatrix} \quad (55)$$

$$V_{dq^{+1}} = V^{+1} \begin{bmatrix} \cos(\omega t - \theta) \\ \sin(\omega t - \theta) \end{bmatrix} + V^{-1} \begin{bmatrix} \cos(\omega t + \varphi^{-1} + \theta) \\ \sin(\omega t + \varphi^{-1} + \theta) \end{bmatrix} \quad (56)$$

$$V_{dq^{-1}} = \begin{bmatrix} v_{d^{-1}} \\ v_{q^{-1}} \end{bmatrix} = [T_{dq^{-1}}] \begin{bmatrix} v_\alpha \\ v_\beta \end{bmatrix} \quad (57)$$

$$V_{dq^{-1}} = V^{+1} \begin{bmatrix} \cos(\omega t + \theta) \\ \sin(\omega t + \theta) \end{bmatrix} + V^{-1} \begin{bmatrix} \cos(\omega t + \varphi^{-1} - \theta) \\ \sin(\omega t + \varphi^{-1} - \theta) \end{bmatrix} \quad (58)$$

Donde $[T_{dq^{+1}}]$ coincide con la transformada de Park original, y $[T_{dq^{-1}}] = [T_{dq^{+1}}]^T$. El superíndice T detona la traspuesta de la matriz.

El sistema de sincronización que se presenta utiliza una estructura similar a la presentada en la figura 7 de acuerdo con (Serrano, 2014), donde la señal $V_{q^{+1}}$ es la señal de entrada a la estructura de PLL básica, y el ángulo estimado determina la posición angular del sistema d^{+1} y q^{+1} . Se puede pensar que este sistema de referencia girará en sincronización al vector de secuencia positiva, es decir, $\theta \approx \omega t$. En estas condiciones las ecuaciones (56) y (58) se pueden escribir como:


$$V_{dq^{+1}} \approx V^{+1} \begin{bmatrix} 1 \\ \omega t - \theta \end{bmatrix} + V^{-1} \begin{bmatrix} \cos(2\omega t + \varphi^{-1}) \\ \sin(2\omega t + \varphi^{-1}) \end{bmatrix} \quad (59)$$

$$V_{dq^{-1}} \approx V^{+1} \begin{bmatrix} \cos(2\omega t) \\ \sin(2\omega t) \end{bmatrix} + V^{-1} \begin{bmatrix} \cos(\varphi^{-1}) \\ \sin(\varphi^{-1}) \end{bmatrix} \quad (60)$$

Según (59) y (60), las componentes directas y en cuadratura del sistema de referencia dq^{+1} tienen un término constante asociado al vector de secuencia positiva más una componente oscilante 2ω que depende de la amplitud del vector de secuencia negativa. Algo similar ocurre para el vector de secuencia negativa sobre el sistema de referencia dq^{-1} .

Las componentes oscilantes en (59) y (60), conllevan a utilizar un filtro pasa bajas de frecuencia de corte baja para eliminar esta componente oscilante. Sin embargo, aún persistirá un error residual en la estimación del módulo y el ángulo del vector de secuencia positiva. En la figura 8 se muestra la estructura completa del DDSRF-PLL, mediante el uso del bloque que desacopla las señales del sistema de referencia dq^{+1} de los efectos del vector de tensión de secuencia negativa, para conseguir que en régimen permanente la señal de salida q^{+1*} que es $v_{q^{+1}}^*$ sea constante. Por lo anterior, la señal $v_{q^{+1}}^*$ se aporta como entrada al bloque de estructura básico del PLL.

Figura 8. Estructura final del DDSRF-PLL



En régimen permanente, la perturbación debido a las componentes oscilantes a 2ω han sido canceladas y la señal $v_{d^{-1}}^*$ coincide con la amplitud del vector de secuencia negativa. Esto sucede porque se ha impuesto que los ángulos de los vectores de secuencia negativa y positiva sean nulos $\varphi^{+1} = \varphi^{-1} = 0$. En caso de que esto no sea así, cuando el PLL se haya estabilizado, se seguirán manteniendo las mismas características que se acaban de mencionar (Serrano, 2014).

Teniendo en cuenta que la posición angular del sistema de referencia dq^{-1} siempre será $-\theta$, y considerando que los ángulos φ^{+1} y φ^{-1} no tienen por qué ser iguales y de signo opuesto, las posiciones de los ejes síncronos de secuencia positiva y negativa no tienen que ser iguales. Por lo tanto, las señales $v_{d^{-1}}^*$ y $v_{q^{-1}}^*$ siempre reflejarán la proyección del vector en el sistema dq^{-1} , y el valor de estas dependerá de la posición angular relativa que ocupe el vector en el sistema de referencia. Es claro que conociendo $v_{d^{-1}}^*$ y $v_{q^{-1}}^*$ y el ángulo, se puede calcular la magnitud y la fase del vector de secuencia negativa aplicando relaciones trigonométricas.

3.4 Modelo para sistema síncrono convencional (SRF-PLL)

La configuración básica del PLL se muestra en la figura 7 (SRF-PLL). Las tensiones v_a, v_b, v_c en las coordenadas abc estacionarias se transforman en v_d y v_q utilizando las transformadas de Clarke y Park (sistema de referencia sincronizado con la frecuencia fundamental de la señal de tensión) (Serrano, 2014). Para el filtro de lazo (PI) (con el fin de comparar los algoritmos con el Filtro Kalman Extendido) se obtiene un tiempo de establecimiento de 14 [ms] y un %SP = 4, entonces por medio de las ecuaciones (52) y (53) se determinan las constantes características del controlador PI. Por lo tanto, se obtiene la siguiente función de transferencia:

$$PI(s) = k_p \left(\frac{1+T_{is}}{T_{is}} \right) = 851 \left(\frac{1+0.0183s}{0.0183s} \right) \quad (61)$$

Para los bloques $[T_{\alpha\beta}]$ y $[T_{dq}]$, que representa la transformada de Clarke y la transformada de Park invariante en magnitud respectivamente, se utilizan las ecuaciones (62) y (63).

$$[T_{\alpha\beta}] = \frac{2}{3} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \quad (62)$$

$$[T_{dq}] = \begin{bmatrix} \cos(\theta) & \sin(\theta) \\ -\sin(\theta) & \cos(\theta) \end{bmatrix} \quad (63)$$

3.5 Modelo para sistema síncrono doble desacoplado (DDSRF-PLL)

Esta segunda técnica se muestra en la figura 8. Con este PLL es posible obtener la componente de secuencia positiva v_d^{+1} y v_q^{+1} , para tensiones desequilibradas. El objetivo de este algoritmo es desacoplar la secuencia positiva y negativa de un vector de tensión (Serrano, 2014).

En esta técnica, el vector de tensión se desacopla en dos componentes que giran a frecuencias $n\omega$ y $m\omega$, respectivamente:

$$V_{\alpha\beta} = \begin{bmatrix} v_{\alpha} \\ v_{\beta} \end{bmatrix} = v_{\alpha\beta}^n + v_{\alpha\beta}^m \quad (64)$$

$$V_{\alpha\beta} = V^n \begin{bmatrix} \cos(n\omega t + \varphi^n) \\ \sin(n\omega t + \varphi^n) \end{bmatrix} + V^m \begin{bmatrix} \cos(m\omega t + \varphi^m) \\ \sin(m\omega t + \varphi^m) \end{bmatrix} \quad (65)$$

Para $n = 1$ y $m = -1$, en la figura 8 se muestra el diagrama de bloques de las dos celdas de desacoplamiento utilizadas para separar las secuencias positivas y negativas, las ecuaciones para los bloques de desacople, según (Serrano, 2014), son las siguientes:

$$\begin{bmatrix} v_{d+1}^* \\ v_{q+1}^* \end{bmatrix} = \begin{bmatrix} v_{d+1} \\ v_{q+1} \end{bmatrix} - \begin{bmatrix} \cos(2\theta) & \sin(2\theta) \\ -\sin(2\theta) & \cos(2\theta) \end{bmatrix} \begin{bmatrix} v_{d-1} \\ v_{q-1} \end{bmatrix} \quad (66)$$

$$\begin{bmatrix} v_{d-1}^* \\ v_{q-1}^* \end{bmatrix} = \begin{bmatrix} v_{d-1} \\ v_{q-1} \end{bmatrix} - \begin{bmatrix} \cos(2\theta) & \sin(2\theta) \\ -\sin(2\theta) & \cos(2\theta) \end{bmatrix} \begin{bmatrix} v_{d+1} \\ v_{q+1} \end{bmatrix} \quad (67)$$

Las señales de salida de las celdas de desacoplamiento (v^*) han de pasar por un filtro pasa bajas (LPF en la figura 8) el cual da lugar a señales v . El filtro tiene una función de transferencia:

$$H(s) = \frac{300}{s + 300} \quad (68)$$

Para el bloque $[T_{\alpha\beta}]$, se utiliza el mismo de la ecuación (62). Para los bloques $[T_{dq+1}]$ y $[T_{dq-1}]$, los cuales son las transformadas de Park para cada componente de secuencia, se emplea:

$$[T_{dq+1}] = \begin{bmatrix} \cos(\theta) & \sin(\theta) \\ -\sin(\theta) & \cos(\theta) \end{bmatrix} \quad (69)$$

$$[T_{dq-1}] = \begin{bmatrix} \cos(-\theta) & \sin(-\theta) \\ -\sin(-\theta) & \cos(-\theta) \end{bmatrix} \quad (70)$$

Finalmente, el filtro de lazo sigue la misma función de transferencia de la ecuación (61), dado que tiene los mismos parámetros.

4. Filtro Adaptativo – LMS

Este algoritmo fue desarrollado por *Widroff* y *Hoff* en 1960, y está fundamentado en el algoritmo de la máxima pendiente, el cual se basa en la ecuación (71) para el reajuste del vector de pesos $\mathbf{w}(n)$ (Díaz y Ortiz, 2010):

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \frac{1}{2} \mu \nabla J(n); n = 1, 2, \dots \quad (71)$$

Donde μ es el parámetro de tamaño de paso y $\nabla J(n)$ es el vector gradiente que sigue la siguiente ecuación:

$$\nabla J(n) = 2\mathbf{p} + 2\mathbf{R}\mathbf{w}(n) \quad (72)$$

Donde $\mathbf{p}$ es el vector de correlación cruzada entre el vector de entradas $\mathbf{u}(n)$ y la respuesta deseada $d(n)$, y $\mathbf{R}$ la matriz de correlación de las entradas. Además, se supone que $\mathbf{p}$ y $\mathbf{R}$ son conocidas. Una aproximación del vector gradiente $\nabla J(n)$, se obtiene al realizar el cálculo inmediato de las matrices $\mathbf{p}$ y $\mathbf{R}$ que se basa en valores muestreados del vector de entrada y la respuesta deseada, de esta forma (Díaz y Ortiz, 2010):

$$\begin{aligned} \hat{\mathbf{p}}(n) &= \mathbf{u}(n)d^*(n) \\ \hat{\mathbf{R}}(n) &= \mathbf{u}(n)\mathbf{u}^H(n) \end{aligned} \quad (73)$$

Donde el superíndice H , denota que se trata del Hermitiano del vector de entradas y el símbolo $*$ detona el conjugado del vector, por lo tanto, reemplazando (73) en (72), se obtiene un valor estimado del vector gradiente:


$$\hat{\nabla} J(n) = -2\mathbf{u}(n)d^*(n) + 2\mathbf{u}(n)\mathbf{u}^H(n) \hat{\mathbf{w}}(n) \quad (74)$$

Al manipular las ecuaciones (74) y (71), se obtiene la siguiente forma recursiva de actualizar el vector de pesos:

$$\hat{\mathbf{w}}(n+1) = \hat{\mathbf{w}}(n) + \mu \mathbf{u}(n)[d^*(n) - \mathbf{u}^H(n) \hat{\mathbf{w}}(n)] \quad (75)$$

Vale la pena mencionar que el origen del algoritmo LMS se basa totalmente en señales estocásticas estacionarias; no obstante, este algoritmo es aplicable también para situaciones determinísticas y estocásticas no estacionarias (Díaz y Ortiz, 2010).

Figura 9. Esquema del filtro adaptativo



Teniendo en cuenta la figura (4.1), el filtro LMS tendrá el siguiente planteamiento matemático:

Dado un vector de entradas de tamaño M en el tiempo n :

$$\mathbf{u}(n) = [u(n), u(n-1), \dots, u(n-M+1)]^T \quad (76)$$

El vector de pesos para comenzar el algoritmo debe tener una condición inicial $\hat{\mathbf{w}}(0)$, y la respuesta deseada $d(n)$, entonces se debe calcular el vector de pesos actualizado $\hat{\mathbf{w}}(n+1)$ en el tiempo $n+1$:

$$\hat{\mathbf{w}}(n+1) = \hat{\mathbf{w}}(n) + \mu \mathbf{u}(n)e^*(n) \quad (77)$$

Donde el error de estimación está dado por:

$$e(n) = d(n) - y(n) \quad (78)$$

Y la salida del filtro está dada por:

$$y(n) = \hat{\mathbf{w}}^H(n)\mathbf{u}(n) \quad (79)$$

4.1 Modelo de señal trifásico propuesto para LMS

A continuación, se presentan los modelos utilizados para la estimación de los parámetros. Un primer planteamiento se utiliza para calcular la magnitud de las componentes de secuencia y el ángulo de fase. Para el cálculo de la frecuencia se utiliza un bloque aparte.

4.1.1 Modelo para estimación de magnitud y ángulo de fase

En este trabajo se propone un modelo de señal para la estimación de la magnitud de las componentes de secuencia, frecuencia y fase a partir de las tensiones de línea de un sistema trifásico, estas señales de tensión están dadas por:

$$y_{ab}(t) = A_{1f} \cos(\omega_1 t + \varphi_1 + 30^\circ) + B_{1f} \cos(\omega_1 t + \theta_1 - 30^\circ) \quad (80)$$

$$y_{bc}(t) = A_{1f} \cos(\omega_1 t + \varphi_1 - 90^\circ) + B_{1f} \cos(\omega_1 t + \theta_1 + 90^\circ) \quad (81)$$

Donde A_{1f} , φ_1 y B_{1f} , θ_1 corresponden con las amplitudes y los ángulos de fase de las componentes de secuencia positiva y negativa de las tensiones de línea, respectivamente.

Aplicando la identidad trigonométrica:

$$\cos(\alpha \pm \beta) = \cos(\alpha)\cos(\beta) \mp \sin(\alpha)\sin(\beta) \quad (82)$$

Las ecuaciones (80) y (81) se pueden reescribir como:

$$\begin{aligned} y_{ab}(t) = & A_{1f} \cos(\varphi_1) \cos(\omega_1 t + 30^\circ) - A_{1f} \sin(\varphi_1) \sin(\omega_1 t + 30^\circ) + \\ & B_{1f} \cos(\theta_1) \cos(\omega_1 t - 30^\circ) - B_{1f} \sin(\theta_1) \sin(\omega_1 t - 30^\circ) \end{aligned} \quad (83)$$

$$\begin{aligned} y_{bc}(t) = & A_{1f} \cos(\varphi_1) \cos(\omega_1 t - 90^\circ) - A_{1f} \sin(\varphi_1) \sin(\omega_1 t - 90^\circ) + \\ & B_{1f} \cos(\theta_1) \cos(\omega_1 t + 90^\circ) - B_{1f} \sin(\theta_1) \sin(\omega_1 t + 90^\circ) \end{aligned} \quad (84)$$

De las ecuaciones (83) y (84) se obtienen las variables

$$\begin{aligned}
 y_{1c}(t) &= \cos(\omega_1 t + 30^\circ) \\
 y_{1s}(t) &= \sin(\omega_1 t + 30^\circ) \\
 y_{2c}(t) &= \cos(\omega_1 t - 30^\circ) \\
 y_{2s}(t) &= \sin(\omega_1 t - 30^\circ)
 \end{aligned} \tag{85}$$

$$\begin{aligned}
 y_{3c}(t) &= \cos(\omega_1 t - 90^\circ) \\
 y_{3s}(t) &= \sin(\omega_1 t - 90^\circ) \\
 y_{4c}(t) &= \cos(\omega_1 t + 90^\circ) \\
 y_{4s}(t) &= \sin(\omega_1 t + 90^\circ)
 \end{aligned} \tag{86}$$

Las ecuaciones (85) y (86) están asociadas con la componente fundamental de las señales de tensión de línea v_{ab} y v_{bc} respectivamente, en un instante t . El filtro LMS hace un ajuste recursivo de sus pesos para determinar la mejor combinación lineal entre ellos y el modelo, y así obtener el error mínimo posible cuya expresión está dada por (78). Para llevar a cabo esta tarea el algoritmo LMS emplea el seguimiento de la señal deseada $d(t)$ de la siguiente manera:

Se define un vector de entrada $\mathbf{u}(t)$ dado por la siguiente ecuación:

$$\mathbf{u}(t) = \begin{pmatrix} y_{1c} & y_{3c} \\ y_{1s} & y_{3s} \\ y_{2c} & y_{2c} \\ y_{2s} & y_{4s} \end{pmatrix} \tag{87}$$

Donde cada columna de la matriz corresponde con la componente fundamental de las tensiones de línea. Por otra parte, el vector de pesos se define en base a las ecuaciones (83) y (84).

$$\mathbf{w} = \begin{pmatrix} w_0 \\ w_1 \\ w_2 \\ w_3 \end{pmatrix} = \begin{pmatrix} A_{1f} \cos(\varphi_1) \\ -A_{1f} \sin(\varphi_1) \\ B_{1f} \cos(\theta_1) \\ -B_{1f} \sin(\theta_1) \end{pmatrix} \quad (88)$$

Por lo tanto, a partir de los pesos se pueden determinar las amplitudes A_{1f} y B_{1f} de secuencia positiva y negativa, respectivamente. También se pueden estimar los ángulos de fase φ_1 y θ_1 de las componentes de secuencia positiva y negativa, respectivamente, como se muestra en las siguientes ecuaciones.

$$\begin{aligned} A_{1f} &= \sqrt{w_0^2 + w_1^2} \\ B_{1f} &= \sqrt{w_2^2 + w_3^2} \end{aligned} \quad (89)$$

$$\begin{aligned} \varphi_1 &= \tan^{-1} \left(-\frac{w_1}{w_0} \right) \\ \theta_1 &= \tan^{-1} \left(-\frac{w_3}{w_2} \right) \end{aligned} \quad (90)$$

Finalmente, las salidas del filtro y el vector de error calculado están dados por las siguientes ecuaciones:

$$\begin{aligned} y_1(t) &= [y_{1c} \quad y_{1s} \quad y_{2c} \quad y_{2s}] * w \\ y_2(t) &= [y_{3c} \quad y_{3s} \quad y_{4c} \quad y_{4s}] * w \end{aligned} \quad (91)$$

$$\begin{aligned} e(t) &= d(t) - y(t) \\ e(t) &= \begin{pmatrix} y_{ab} \\ y_{bc} \end{pmatrix} - \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \end{aligned} \quad (92)$$

4.1.2 Modelo para estimación de frecuencia

En la estimación de las magnitudes y ángulos de fase de las componentes de secuencia, se emplea un modelo de señal que corresponde a una combinación lineal entre los pesos del filtro y el modelo. Sin embargo, para estimar frecuencia variante en el tiempo. Se propone un modelo que es extrapolado a partir de (Kušljević, 2008), puesto que la frecuencia no es conocida y esta no guarda una relación lineal con los pesos del filtro.

En primer lugar, este modelo de señal se acopla con el modelo para la estimación de magnitud y fase anteriormente descrito para que estén sincronizados. Así solo se necesita una señal de línea para detectar la frecuencia, en este caso se utiliza la tensión de línea v_{ab} que está descrita por la ecuación (80). Entonces, al elevar al cuadrado la ecuación (80) se obtiene:

$$y_{ab}^2(t) = A_{1f}^2 \cos^2(\omega_1 t + \varphi_1') + 2A_{1f}B_{1f} \cos(\omega_1 t + \varphi_1') \cos(\omega_1 t + \theta_1') + B_{1f}^2 \cos^2(\omega_1 t + \theta_1') \quad (93)$$

Donde $\varphi_1' = \varphi_1 + 30^\circ$ y $\theta_1' = \theta_1 - 30^\circ$ corresponden con los ángulos de fase de las componentes de secuencia. Operando en el tiempo la ecuación (93), es decir, se retrasa la señal a los tiempos $t - \Delta t$ y $t - 2\Delta t$, se obtiene:

$$y_{ab}^2(t - \Delta t) = A_{1f}^2 \cos^2(\omega_1(t - \Delta t) + \varphi_1') + 2A_{1f}B_{1f} \cos(\omega_1(t - \Delta t) + \varphi_1') \cos(\omega_1(t - \Delta t) + \theta_1') + B_{1f}^2 \cos^2(\omega_1(t - \Delta t) + \theta_1') \quad (94)$$

$$y_{ab}^2(t - 2\Delta t) = A_{1f}^2 \cos^2(\omega_1(t - 2\Delta t) + \varphi_1') + 2A_{1f}B_{1f} \cos(\omega_1(t - 2\Delta t) + \varphi_1') \cos(\omega_1(t - 2\Delta t) + \theta_1') + B_{1f}^2 \cos^2(\omega_1(t - 2\Delta t) + \theta_1') \quad (95)$$

Desde las ecuaciones (94) y (95), se llega a la siguiente expresión:

$$y_{ab}^2(t) + y_{ab}^2(t - 2\Delta t) = \mathbf{u}' * \mathbf{w}' \quad (96)$$

Donde $\mathbf{u}'$ y $\mathbf{w}'$ son el vector de entrada y de pesos respectivamente, y están dados por las siguientes ecuaciones:

$$\begin{aligned}\mathbf{u}' &= (1 \quad 2y_{ab}^2(t - \Delta t)) \\ \mathbf{w}' &= \begin{pmatrix} w_4 \\ w_5 \end{pmatrix} = \begin{pmatrix} K(1 - \cos(2\omega_1\Delta t)) \\ \cos(2\omega_1\Delta t) \end{pmatrix}\end{aligned}\quad (97)$$

Donde K viene dado por la siguiente expresión:

$$K = A_{1f}^2 + B_{1f}^2 + 2A_{1f}B_{1f}\cos(\varphi_1' - \theta_1') \quad (98)$$

Suponiendo que se realiza un muestreo constante, es decir, una frecuencia de muestreo $f_s = 1/\Delta t$, se obtiene la siguiente ecuación discreta en el tiempo para la salida del filtro y el error:

$$\begin{aligned}y(n) &= \mathbf{u}' * \mathbf{w}' \\ e(n) &= d(n) - y(n)\end{aligned}\quad (99)$$

Donde $d(n)$ es la señal deseada que es la asociada con la medida.


$$d(n) = v^2(n) + v^2(n - 2) \quad (100)$$

Por último, de la ecuación (97) del vector de pesos se puede estimar la frecuencia angular del sistema dada por:

$$\omega_1 = \frac{\cos^{-1}(w_5)}{2} * f_s \quad (101)$$

La frecuencia estimada realimenta las variables de la componente fundamental de las ecuaciones (85) y (86), con el fin de sincronizar ambos sistemas LMS. Finalmente, en la figura 10 se presenta un esquema ilustrativo del algoritmo LMS propuesto para la estimación de los parámetros de una señal de tensión trifásica.

Figura 10. Esquema LMS trifásico



5. Filtro Notch Adaptativo - ANF

En este algoritmo se presenta el método de sincronización propuesto en (Mojiri, 2019), el cual es un filtro Notch adaptativo modificado de ecuaciones no lineales. La señal de entrada será modelada por una suma de sus componentes armónicas, dada por:

$$u(t) = \sum_{i=1}^n A_i \sin(\omega_i + \varphi_i) \quad (102)$$

Donde A_i , ω_i , φ_i son la amplitud, frecuencia y fase de cada armónico de la señal de entrada.

5.1 Dinámica y estructura

En este trabajo se emplea el ANF de tiempo discreto basado en (Mojiri y Bakhshai, Feb 2004), (Mojiri y Ghartemani, 2007) y (Mojiri y Bakhshai, April 2004). El comportamiento dinámico de este ANF se caracteriza por el siguiente conjunto de ecuaciones diferenciales:

$$\begin{aligned}\ddot{x} + \theta x &= 2\xi\theta e(t) \\ \dot{\theta} &= -\gamma x\theta e(t) \\ e(t) &= u(t) - \dot{x}\end{aligned}\tag{103}$$

Donde θ es la frecuencia estimada, y ξ y γ son parámetros reales positivos ajustables que determinaran la exactitud y la velocidad de convergencia del ANF. Para una sinusoidal pura, este ANF tiene un único periodo de orbita ubicado en (Mojiri, 2019):

$$O = \begin{pmatrix} \bar{x} \\ \dot{\bar{x}} \\ \bar{\theta} \end{pmatrix} = \begin{pmatrix} -\frac{A_1}{\omega_1} \cos(\omega_1 t + \varphi_1) \\ A_1 \sin(\omega_1 t + \varphi_1) \\ \omega_1 \end{pmatrix}\tag{104}$$

La tercera fila de O es la frecuencia estimada, la cual es idéntica a su valor correcto ω_1 .

5.2 Análisis de estabilidad

Las ecuaciones dinámicas en (103) son estables lo que significa que el ANF es estable, eso está demostrado en (Mojiri y Bakhshai, Feb 2004), (Mojiri y Ghartemani, 2007) y (Mojiri y Bakhshai, April 2004). Sin embargo, se echará un vistazo a su estabilidad, usando la primera ecuación, el término de la ley de actualización se puede reescribir como:

$$\dot{\theta} = -\frac{\gamma}{2\xi} x(\ddot{x} + \theta^2 x)\tag{105}$$

Cerca del periodo de orbita O , donde $\bar{\theta} = \omega_1$ y $\ddot{\bar{x}} = -\omega_1^2 \bar{x}$, entonces se tiene:

$$\dot{\theta} \approx -\frac{\gamma}{2\xi} x^2(\theta^2 - \omega_1^2)\tag{106}$$

La derivación anterior, muestra que cerca de la órbita deseada el proceso de adaptación es lento y en la búsqueda del parámetro espacial de θ se irá en la dirección correcta (Mojiri, 2019).

5.3 Unidad para sincronización con la red

La figura 11 muestra la estructura del algoritmo de sincronización de red propuesto en (Mojiri, 2019), donde el ANF funciona como bloque principal. La entrada es una señal periódica (ecuación 102). La ventaja de esta estructura se debe a la información de señal útil que puede aportar como: la componente fundamental, la componente en cuadratura, la amplitud, frecuencia y funciones del ángulo de la componente fundamental y los armónicos.


Como se puede observar en las ecuaciones (103) y (104), la componente fundamental y en cuadratura, son $\dot{\bar{x}}$ y $\bar{\theta}\bar{x}$, respectivamente. Por lo tanto, la amplitud de la componente fundamental se puede calcular como:

$$A_1 = \sqrt{\bar{\theta}^2 \bar{x}_1^2 + \dot{\bar{x}}_1^2} \quad (107)$$

En la figura (11) se muestra una implementación detallada de la estructura. La salida θ proporciona la frecuencia de la señal de entrada ω_1 , y el ANF se compone de sumadores, multiplicadores e integradores. La función del argumento de la componente fundamental se obtiene dividiendo la componente fundamental $\dot{\bar{x}}$ y su componente en cuadratura ($\bar{\theta}\bar{x}$) como se muestra en la ecuación 108.

$$\omega_1 t + \varphi_1 = \tan^{-1} \left(\frac{\dot{\bar{x}}}{\bar{\theta}\bar{x}} \right) \quad (108)$$

Figura 11. Estructura del ANF



5.4 Parámetros del filtro y condición inicial

La estructura de la figura 11 muestra dos parámetros independientes. El parámetro γ determina la velocidad de adaptación, por lo tanto, la capacidad del algoritmo para rastrear variaciones de las características de la señal. En particular, la tasa de convergencia de la frecuencia estimada es proporcional a γ . El parámetro ξ determina la profundidad de la ranura o la sensibilidad al ruido del filtro. Se puede hacer una compensación entre la precisión (régimen permanente) y la velocidad de convergencia (transitorio) ajustando los parámetros de diseño. Al aumentar γ se puede lograr una velocidad de convergencia mayor, sin embargo, al mismo tiempo se debe aumentar ξ para evitar oscilaciones.

La condición inicial para el integrador que genera la frecuencia debe ser la frecuencia angular fundamental de la señal de entrada. Las condiciones iniciales para los otros integradores son cero.

5.5 Estructura particular para sistemas trifásicos

En el marco de referencia abc , la implementación del algoritmo de sincronización se puede realizar mediante tres ANF anteriormente mencionados. Los tres ANF extraen la información necesaria de la red con el fin de hacer la estimación. Una ventaja del algoritmo es que proporciona información sobre amplitud, frecuencia y ángulo de fase para cada una de las fases.

Al considerar lo anterior, el concepto de componentes simétricas de Fortescue para fasores puede extenderse a las señales como funciones del tiempo reemplazando el fasor complejo $a = e^{j120^\circ}$, con 120° de cambio de fase en el dominio del tiempo (Mojiri, 2019).

Una señal de tensión trifásica puede ser descompuesta como:

$$v(t) = v^+(t) + v^-(t) + v^0(t) \quad (109)$$

Donde $v^+(t)$, $v^-(t)$ y $v^0(t)$ son las componentes de secuencia positiva, negativa y cero, respectivamente. Las componentes de secuencia pueden ser determinadas como:

$$\begin{aligned} v^+(t) &= T_2 X_1(t) + T_1 X_2(t) \\ v^-(t) &= T_2 X_1(t) - T_1 X_2(t) \\ v^0(t) &= (I - 2T_2) X_1(t) \end{aligned} \quad (110)$$

Donde $X_1(t)$ y $X_2(t)$, representan la componente fundamental y la componente en cuadratura, respectivamente. T_1 y T_2 son matrices 3×3 , dadas por (Mojiri, 2019):


$$T_1 = \frac{1}{2\sqrt{3}} \begin{pmatrix} 0 & 1 & -1 \\ -1 & 0 & 1 \\ 1 & -1 & 0 \end{pmatrix} \quad (111)$$

$$T_2 = \frac{1}{3} \begin{pmatrix} 1 & -0.5 & -0.5 \\ -0.5 & 1 & -0.5 \\ -0.5 & -0.5 & 1 \end{pmatrix} \quad (112)$$

Donde I es una matriz identidad 3×3 .

El algoritmo extrae la secuencia positiva y negativa, como se muestra en la figura 12. Este se compone de tres ANF y operadores aritméticos triviales. Estos extraen de manera adaptativa las componentes fundamentales y sus componentes en cuadratura. El sistema aritmético recibe estos componentes y calcula los voltajes de secuencia positiva y negativa basándose en (109) y (110). El componente de secuencia positivo extraído se puede pasar por otro ANF para obtener información para la sincronización con la red, donde el bloque de componentes simétricas instantáneas está en función de (110) y (111).

Figura 12. Esquema ANF trifásico con componentes de secuencia



Fuente: adaptada de (Mojiri, 2019)

6. Evaluación de desempeño mediante simulación en MATLAB/SIMULINK

A continuación, se presenta el capítulo donde se definen diferentes tipos de perturbaciones que pueden ocurrir en la señal de tensión de la red, los criterios para la evaluación de desempeño de los algoritmos, los detalles de los escenarios de prueba, y los resultados de simulación de cada uno de los algoritmos para los distintos escenarios.

6.1 Tipos de perturbaciones

En este capítulo se evaluará el comportamiento de los algoritmos de sincronización ante diferentes tipos perturbaciones que pueden ocurrir en la red de energía eléctrica. Entre las diferentes perturbaciones que pueden ocurrir se estudiarán las que se presentan a continuación:

- Hundimientos de tensión
- Variación de frecuencia
- Distorsión armónica

6.1.1 Hundimientos de tensión

Según el estándar IEEE 1159 (IEEE 1159 standards association, 2019), un hundimiento de tensión es un evento caracterizado por la disminución del voltaje RMS entre 0.1 pu y 0.9 pu durante periodos de 0.5 ciclos a 1 minuto. Al describir la magnitud de la caída de tensión suele ser interpretada de diferentes formas, por ejemplo, un hundimiento del 20% puede significar 0.2 pu o 0.8 pu. Por lo tanto, la forma de describir estos hundimientos es por el voltaje retenido o voltaje restante, como se muestra en la figura 13.

Las caídas de tensión son reducciones en el voltaje RMS, causada por cortocircuitos, sobrecargas y arranque de motores grandes. El interés en estos efectos se debe principalmente a

los problemas que causan en equipos como: variadores de velocidad, equipos de control de procesos y computadoras si es notable su sensibilidad.


Algunos equipos no continúan operando cuando el voltaje RMS cae por debajo de 90% del voltaje de referencia a la frecuencia fundamental. Por supuesto, una caída de voltaje no es tan dañina como una interrupción del suministro, pero como hay muchas más caídas de tensión que interrupciones el daño total de las caídas es mayor (Manrique y Plata, 2019).

6.1.1.1 Características de los hundimientos de tensión

Profundidad del hundimiento de tensión: Se define como la diferencia entre la tensión de referencia y la tensión residual o restante durante el evento. La tensión residual se conoce también como la magnitud del hundimiento de tensión.

Tensión de referencia: Es el valor especificado como la base sobre la cual se define la profundidad, umbrales y otros valores que caracterizan a un hundimiento de tensión, esto se muestra en la figura 13.

Duración del hundimiento de tensión: Es el tiempo en el cual la tensión tiene una disminución en el valor RMS entre 0.1 y 0.9 pu, con duración entre 0.5 ciclos y 1 minuto (ver figura 6.1). Dentro de este tiempo se pueden clasificar los hundimientos de la siguiente forma: Instantáneos (duración entre 0.5 y 30 ciclos), momentáneos (duración entre 30 ciclos y 3 segundos), y temporales (duración entre 3 segundos a 1 minuto).

Figura 13. *Hundimiento de tensión ilustrativo*

6.1.2 Variaciones de frecuencia

Para un sistema de potencia robusto, son posibles, aunque muy excepcionales, las condiciones para que se produzca un desequilibrio entre la generación y la carga, dando lugar a una variación de frecuencia.

La resolución CREG 025 de 1995 (Resolución CREG 025, 1995), en la sección del código de operación establece que la frecuencia nominal del sistema colombiano es de 60 [Hz] y en condiciones normales el rango de variación está comprendido entre 59.8 – 60.2 [Hz]. Frente a perturbaciones, estados de emergencia, déficit y periodos de restablecimiento, la frecuencia puede variar entre 57.5 – 63 [Hz] por un periodo de quince segundos.

Contextualizando que variaciones de frecuencia se pueden presentar en dos diferentes sistemas de potencia, con base en las investigaciones dadas en las referencias (Muñoz et al, 2009) y (Mukherjee) se muestran los rangos en los que se presentaron estas variaciones. El primero para un sistema de potencia robusto, como el sistema de potencia mexicano de (Muñoz et al, 2009) y

su estudio de variaciones de frecuencia, la cual alcanza un rango de -0.3 a 0.3 [Hz] con una frecuencia nominal de 60 [Hz]. Por otro lado, de (Mukherjee) se nota una variación máxima de 0.5 [Hz] bajo condiciones normales de operación en una red de baja potencia de 100 [kVA].

6.1.3 Distorsión armónica

Se llama armónico a una superposición en la onda de frecuencia fundamental (60 [Hz]), de ondas igualmente sinusoidales, pero con frecuencias múltiplo de la fundamental. La distorsión es causada por la introducción en la red de cargas no lineales como los equipos que hacen parte de la electrónica de potencia. Generalmente todos estos equipos incorporan rectificadores y esta electrónica de corte deforman las corrientes originando variaciones de tensión en la red general de energía eléctrica (Parra y Toro, 2009).

6.2 Criterios para evaluación de desempeño

Para medir el desempeño (estabilidad, convergencia, exactitud y robustez), de los algoritmos de sincronización y compararlos entre sí, se tienen en cuenta los siguientes criterios de medida:

- **Porcentaje de sobrepaso máximo (%SP):** Es la medida en porcentaje del primer pico máximo que presenta la señal estimada con respecto al valor de referencia y se calcula de la siguiente manera (Diaz y Ortiz, 2010):

$$\%SP = \frac{Valor_{pico} - Valor_{ref}}{Valor_{ref}} * 100\% \quad (113)$$

- **Error en estado estable (EeEE):** Esta variable es una medida del error de estimación en estado estable y se calcula mediante la diferencia del valor de referencia y el valor en estado estable de la estimación del algoritmo (Diaz y Ortiz, 2010):

$$e(n) = d(n) - y(n) \quad (114)$$


Donde la variable $e(n)$ denota el error de estimación, $y(n)$ es la salida del algoritmo de sincronización y $d(n)$ representa la señal de referencia.

-Tiempo de establecimiento (T_{est}): Es el tiempo que requiere el algoritmo para que la señal estimada alcance el rango de valores permitidos por el criterio de $\pm 2\%$ (0.98–1.02) [pu] alrededor del valor de referencia y permanezca en él (Díaz y Ortiz, 2010). Para todos los parámetros de la componente fundamental se utilizará lo anteriormente mencionado excepto para la frecuencia. Según lo mencionado en la sección 6.1.2, para la estimación de la frecuencia se tendrá un criterio entre el 99.9 – 1.001% ya que se encuentra en los dos rangos permitidos establecidos por la CREG 025 de 1995 en operación normal del sistema de potencia y en condiciones anormales.

En la figura 14 se muestran las variables de medida definidas anteriormente, éstas se emplean para describir cuantitativamente las características de desempeño de los algoritmos de sincronización, y así establecer jerarquización dependiendo de sus resultados por criterio.

En este contexto, el porcentaje de sobrepaso máximo $\%SP$ se utiliza para evaluar la estabilidad de los algoritmos, de la siguiente manera: el algoritmo que presente menor $\%SP$ es el más estable. Por otra parte, la velocidad de convergencia se evalúa teniendo en cuenta el tiempo de establecimiento T_{est} del algoritmo. Por lo tanto, a menor T_{est} mayor velocidad de convergencia. La exactitud se evalúa así: el algoritmo que presente menor $EeEE$ será el más exacto. Y, por último, la robustez de los algoritmos se evalúa teniendo en cuenta el $EeEE$ bajo la presencia de armónicos. Entonces, el algoritmo que presente menor $EeEE$ será considerado el más robusto (Díaz y Ortiz, 2010).

Figura 14. Curva ilustrativa de los criterios de desempeño.



Fuente: adaptada de (Ogata, 2010).

6.3 Escenarios de simulación


Los algoritmos de sincronización se simulan bajo diferentes escenarios usando el entorno de simulación MATLAB/SIMULINK. En la estimación de las componentes de secuencia, frecuencia, magnitud y fase de la componente fundamental de la señal de tensión trifásica se emplean cuatro casos diferentes de prueba:

- **Primer escenario:** Corresponde a una caída de tensión monofásica a tierra durante un tiempo de 200 [ms], con los siguientes parámetros (definidos en (Camacho et al, 2013)):

Tabla 1 . *Parámetros hundimiento de tensión primer Escenario*


Hundimiento de tensión			
Fasor	Antes	Durante	Después
V_a	$1\angle 0^\circ$	$1.025\angle 0^\circ$	$1\angle 0^\circ$
V_b	$1.01\angle -117^\circ$	$0.78\angle -133^\circ$	$1.01\angle -117^\circ$
V_c	$1.01\angle 122^\circ$	$0.82\angle 132^\circ$	$1.01\angle 122^\circ$
V^+	$1.001\angle 1.67^\circ$	$0.862\angle -0.11^\circ$	$1.001\angle 1.67^\circ$
V^-	$0.016\angle -118.4^\circ$	$0.182\angle -3.57^\circ$	$0.016\angle -118.4^\circ$

La señal considerada en este escenario corresponde a una tensión trifásica sinusoidal a una frecuencia de 60 [Hz] sin distorsión armónica. En la figura 15 se presenta la tensión trifásica para este escenario con los parámetros definidos en la tabla 1.

Figura 15. *Tensión trifásica del escenario 1*

- **Segundo escenario:** Corresponde a un hundimiento de tensión trifásico simétrico de secuencia positiva dado por la curva de requisito LVRT de (Rodríguez et al, 2018). Esta curva se presenta en la figura 16 y corresponde con la señal de entrada a los algoritmos de estudio.

Figura 16. Curva de requisito LVRT de (Rodríguez et al, 2018)




- **Tercer escenario:** Este escenario corresponde con un cambio de frecuencia de 60 a 61 [Hz] en $t = 1$ [seg] para una señal de tensión trifásica de secuencia positiva balanceada y sin distorsión armónica. Se escoge esta magnitud de la variación de la frecuencia, teniendo en cuenta que está dentro del rango permitido de operación según (Resolución CREG 025, 1995), para el sistema de potencia colombiano en condiciones excepcionales de operación.

- **Cuarto escenario:** Como se muestra en la figura 17, la tensión de entrada al algoritmo para este escenario corresponde con la señal empleada en el escenario 1 adicionándole un modelo de señal compuesto por el 5° y 7° armónico, donde estas componentes tienen un 2.45% y 3.95% de amplitud de la componente fundamental, respectivamente. Los datos de distorsión armónica

seleccionados están basados en el manual Programmable AC source 61511/61512 Chroma de (Chroma ANC INC, 2012), forma de onda #16, dado que la universidad posee este equipo y facilitará en un futuro la implementación de los algoritmos.

Figura 17. *Tensión trifásica del escenario 4*



Por otra parte, en la evaluación del desempeño de los algoritmos frente a los casos de prueba mencionados, se tiene en cuenta lo siguiente:

Los algoritmos se simulan con una frecuencia de muestreo de 10 [kHz], los parámetros de ajuste de todos los algoritmos se sintonizaron empíricamente antes de realizar simulaciones. Estos se presentan en la tabla 2 y se mantienen fijos en los cuatro escenarios de prueba para efectos de comparación.

Tabla 2. *Parámetros de simulación*

PARAMETROS DE AJUSTE DE LOS ALGORITMOS	
KALMAN	PLL
$Q = 0,01$ $R = 0,1$ $P = 0,01$ $\epsilon = 1 * 10^{-17}$	$k_p = 851$ $T_i = 0,0183$
Las condiciones de los estados son cero excepto el estado de la frecuencia	Las ganancias del detector de fase y del VCO son unitarias
LMS	ANF
$\mu = 0,09$	$\xi = 0,75$ $\Upsilon = -40000$
Este parámetro es igual en ambos LMS (el de detección de magnitud y ángulo de fase y el de frecuencia).	Las condiciones iniciales de los integradores están en cero excepto los asociados a la frecuencia.

6.4 Resultados de simulación

A continuación, se presentan los resultados de simulación obtenidos en la estimación de las componentes de secuencia, frecuencia, magnitud y fase de la componente fundamental por parte de cada uno de los algoritmos en los cuatro casos de prueba.

6.4.1 Simulación Kalman Extendido con filtro Butterworth


En esta sección se presenta la simulación del algoritmo Kalman con filtro Butterworth ante cada uno de los escenarios de prueba definidos anteriormente, para la estimación de los parámetros de la componente fundamental.

Escenario 1:

En la figura 17 (ver sección 6.3), se muestra la tensión trifásica de entrada al algoritmo la cual esta descrita numéricamente por los parámetros de la tabla 1.


A continuación, se muestra la estimación de la magnitud de las componentes de secuencia. Como se puede apreciar en la figura 18, el algoritmo estima correctamente las magnitudes y tarda alrededor de 11.47 [ms] en alcanzar el 98% del valor de estado estable.

Figura 18. *Magnitud de las componentes de secuencia – Kalman*



Por otra parte, en la figura 19 se presenta la estimación de la frecuencia fundamental por parte del algoritmo. Este responde correctamente y su estimación tiene variaciones que son del orden de $5 * 10^{-4}$ [Hz], estas no se alcanzan a percibir en la figura, y se considera instantánea la estimación en el momento que ocurre el hundimiento de tensión, porque de acuerdo con el criterio del tiempo de establecimiento la frecuencia se mantiene en el rango establecido.


Figura 19. *Frecuencia estimada – Kalman*



En la figura 20 se observa la estimación del argumento de la componente de secuencia positiva a la frecuencia fundamental y el error estimado por parte del algoritmo. A partir de la señal de error del argumento se observa que el algoritmo responde adecuadamente y tarda 14.76 [ms] en establecerse hasta el 98% de su valor en estado estable, es decir, eso equivale a cuando el error llega al 2%.

Por otra parte, en la figura 20 se aprecia un pico en la señal de error. Sin embargo, esto no es una mala estimación del argumento, sino un cambio producido debido a la acotación del argumento entre $-\pi$ y π [rad]. Cuando ocurre el hundimiento de tensión se presenta un transitorio entonces al realizar la resta de la señal ideal con la estimada para calcular el error, los límites de las señales no coinciden y se generan estos picos.


Figura 20. *Argumento estimado por el filtro Kalman y error del argumento.*




Escenario 2:

Se procede a analizar el escenario 2 descrito en la sección 6.3. La figura 21 presenta la estimación de la magnitud de las componentes de secuencia. Esta estimación se realiza correctamente por parte del algoritmo en un tiempo de 14.8 [ms] para el criterio del 98% del valor de referencia en el primer cambio de amplitud (el más brusco), y finalmente estima correctamente la curva con pendiente como se puede apreciar en la figura.

Figura 21. *Magnitud de las componentes de secuencia – Kalman*




Por otra parte, en la figura 22 se muestra la estimación de la frecuencia fundamental durante la ocurrencia de todo el hundimiento de tensión. En el primer cambio de amplitud se tarda alrededor de 167.3 [ms] en llegar al 99.9% del valor nominal y es el momento más crítico porque es cuando ocurre el hundimiento de mayor magnitud.


Figura 22. *Frecuencia estimada – Kalman*

Finalmente, en la figura 23 se muestra la estimación del argumento de la componente fundamental y el error resultante de esta estimación. Dada la dificultad de observar a simple vista las características de la respuesta transitoria en la estimación del argumento, se calcula el error de su estimación, por lo que a partir de la figura del error se observa que la estimación tarda 117.5 [ms] en llegar al 98% del argumento ideal después de la ocurrencia del primer cambio de amplitud (cambio brusco).


Figura 23. Estimación del argumento y el error – Kalman

**Escenario 3:**

Ahora se procede con el análisis del algoritmo para el tercer escenario, este corresponde con una variación de frecuencia de 1 [Hz] como esta descrito en la sección 6.3. En la figura 24 se muestra la estimación de la magnitud de las componentes de secuencia, para tal efecto el algoritmo estima correctamente las componentes en 40 [ms] al llegar al 98% del valor de referencia.


Figura 24. *Magnitud de las componentes de secuencia - Kalman*

En la figura 25 se muestra la estimación de la frecuencia fundamental por parte del algoritmo, esta es estimada correctamente y tarda alrededor de 84.45 [ms] en llegar al 99.9% del valor de referencia.

Figura 25. *Frecuencia estimada – Kalman*

Por otra parte, en la figura 26 se muestra la estimación del argumento de la componente fundamental y su error, como se mencionó antes el error permite apreciar el transitorio en la estimación. Por lo tanto, al ocurrir el cambio en la frecuencia, el algoritmo es capaz de estimar correctamente el argumento de la componente fundamental y tarda alrededor de 44.57 [ms] al llegar al 98% como se aprecia en la figura del error.

Figura 26. *Estimación del argumento y el error - Kalman*




Escenario 4:

En primer lugar, la tensión de entrada al algoritmo se presenta en la figura 17. Esta está descrita explícitamente en el escenario 4 de simulación, en el cual se produce un hundimiento de tensión con las mismas características del primer escenario, pero en este caso la señal de tensión contiene dos componentes armónicas (5° y 7° armónico). Así, en la figura 27 se muestra la estimación de la magnitud de las componentes de secuencia a la frecuencia fundamental, las cuales


son estimadas correctamente tardándose alrededor de 11.8 [ms] en llegar al criterio de tiempo de establecimiento mencionado.

Figura 27. Magnitud de las componentes de secuencia – Kalman




Por otra parte, en la figura 28 se muestra la correcta estimación de la frecuencia fundamental y se considera instantánea porque presenta variaciones del orden de $5 * 10^{-4}$ [Hz], que cumplen el criterio de tiempo de establecimiento, además por esta razón son imperceptibles en la figura.

Figura 28. Frecuencia estimada – Kalman



Finalmente, en la figura 29 se muestra la estimación del argumento y el error de la componente fundamental, como se puede apreciar en la figura del error el algoritmo emplea 14.8 [ms] en aproximarse al 98% del argumento ideal.

Figura 29. Estimación del argumento y el error – Kalman




6.4.2 Simulación DDSRF-PLL


En esta sección se presenta la simulación del algoritmo DDSRF-PLL ante cada uno de los escenarios de prueba definidos en la sección 6.3 para la estimación de los parámetros de la componente fundamental.

Escenario 1:

Ahora a analizar el algoritmo DDSRF-PLL ante la tensión de entrada de la figura 15. Así, en la figura 30 se muestra la estimación de la magnitud de las componentes de secuencia, estas son estimadas correctamente y el algoritmo tarda 15.16 [ms] en llegar al 98% del valor de referencia.


Figura 30. *Magnitud de las componentes de secuencia - DDSRF-PLL*

Por otra parte, el algoritmo realiza correctamente la estimación de la frecuencia fundamental empleando un tiempo de 42.23 [ms] en alcanzar el 99.9% del valor nominal de la frecuencia como se muestra en la figura 31. Sin embargo, este presenta un valor pico durante el transitorio de alrededor del 120% en cada cambio de amplitud.

Figura 31. *Estimación de la frecuencia - DDSRF-PLL*

En la figura 32 se presenta la estimación del argumento de la componente fundamental y su error de estimación. A partir del error se observa que la estimación es correcta y tarda aproximadamente 17.5 [ms] (poco más de un ciclo de la señal fundamental de entrada), en llegar al rango de valores del criterio del tiempo de establecimiento.


Figura 32. Estimación del argumento y el error – DDSRF-PLL



Escenario 2:


Inicialmente en la figura 33 se muestra la estimación de la magnitud de las componentes de secuencia ante la señal de tensión descrita en el escenario 2 de simulación, para lo cual el algoritmo responde correctamente y emplea 26.15 [ms] en llegar al 98% del valor de referencia.

Figura 33. Estimación de las componentes de secuencia - DDSRF-PLL




En la figura 34 se muestra la estimación de la frecuencia. Como se aprecia en la figura el algoritmo responde correctamente, pero con un transitorio brusco dado que tiene un valor pico de 151% de la frecuencia nominal durante el primer cambio de amplitud, tarda alrededor de 22.91 [ms] en la estimación para el 99.9%.

Figura 34. Frecuencia estimada - DDSRF-PLL



Por otro lado, en la figura 35 se presenta la estimación del argumento de la componente fundamental y el error de esta ante la señal de entrada. El algoritmo tarda 35.16 [ms] en llegar al 98% de la estimación del argumento con un transitorio muy brusco dado que tiene un valor pico de 78.71% determinado a partir del error.


Figura 35. *Estimación del argumento y el error – DDSRF-PLL*



Escenario 3:


Siguiendo con el análisis de los escenarios para el algoritmo DDSRF-PLL, este escenario corresponde con la variación de frecuencia de 1 [Hz] descrito en la sección 6.3. En la figura 36 se muestra la estimación de la magnitud de las componentes de secuencia de la señal fundamental de tensión. La estimación de la magnitud presenta variaciones del orden de $1,4 \times 10^{-3}$ [pu], se toma que el algoritmo estima instantáneamente las componentes de secuencia porque está dentro del rango de tolerancia del tiempo de establecimiento.

Figura 36. Magnitud de las componentes de secuencia - DDSRF-PLL




Siguiendo con la estimación de los parámetros, en la figura 37 se presenta la estimación de la frecuencia fundamental. En este caso la frecuencia es estimada correctamente y tarda alrededor de 17.66 [ms] (poco más de un ciclo de la señal fundamental) en llegar al 99.9% de su valor nominal.

Figura 37. Frecuencia estimada - DDSRF-PLL



En la figura 38, se muestra la estimación del argumento de la componente fundamental y su error. A partir de la figura del error se aprecia que las variaciones están del orden de $5 \text{ a } 10 \times 10^{-3}$, entonces se considera que su estimación es instantánea porque por definición del criterio el tiempo de establecimiento es instantáneo.


Figura 38. Estimación del argumento y el error – DDSRF-PLL



Escenario 4:


Finalmente, se procede con el análisis de simulación del algoritmo ante la tensión de entrada de la figura 17, la cual corresponde con la descrita en el escenario 4 de simulación. En la figura 39 se muestra la estimación de la magnitud de las componentes de secuencia. En este caso se observa que la distorsión armónica en la tensión de entrada provoca un rizo a la salida del algoritmo. El algoritmo tarda alrededor de 34.84 [ms] en llegar a la banda del $\pm 2\%$ del valor de la tensión de secuencia positiva de referencia con un EeEE de 0.01 [V].

Figura 39. Estimación de la magnitud de las componentes de secuencia - DDSRF-PLL




A continuación, se presenta el resultado de la estimación de la frecuencia fundamental. Como se observa en la figura 40 esta presenta un rizo de 10 [Hz] pico a pico debido a la distorsión armónica durante el hundimiento de tensión. Al presentar este EeEE de 5 [Hz] se puede decir que no tiene un tiempo de establecimiento ya que no llega a la banda del $\pm 0.1\%$.

Figura 40. Frecuencia estimada - DDSRF-PLL



Por otro lado, se presenta el resultado de la estimación del argumento de la componente fundamental y su error. Como se observa en el error de la figura 41, el argumento tarda 31.47 [ms] en llegar a la banda del $\pm 2\%$, además es visible como el argumento al igual que los demás parámetros se ve afectado por la distorsión armónica.

Figura 41. *Estimación del argumento de la componente fundamental - DDSRF-PLL*




6.4.3 Simulación LMS

En esta sección se estudian los resultados de simulación del algoritmo LMS ante los diferentes escenarios de simulación definidos en la sección 6.3. Para tal efecto, se presenta la estimación de los parámetros de la componente fundamental para cada escenario.

Escenario 1:


El primer escenario corresponde con la estimación del hundimiento de tensión presentado en la figura 15. En la figura 42 se muestra la estimación de la magnitud de las componentes de secuencia por parte del algoritmo LMS, estas tardan 66.4 [ms] en llegar al 98% del valor de referencia cuando ocurre el hundimiento de tensión.

Figura 42. *Magnitud de las componentes de secuencia – LMS*




Siguiendo con el análisis de los resultados, se presenta la estimación de la frecuencia fundamental ante la tensión de entrada. Tal y como se observa en la figura 43, cuando inicia el hundimiento de tensión su transitorio es moderado ya que alcanza un pico de 61.92 [Hz] y tarda 135.8 [ms] en llegar al 100.1%. Cuando termina el hundimiento de tensión presenta un pico de 98 [Hz] que tarda 150 [ms] en reducirse hasta el 100.1% del valor de la frecuencia fundamental, cabe resaltar que tarda 22 [ms] en llegar al 101%.

Figura 43. Frecuencia fundamental estimada – LMS



En la figura 44 se presenta la estimación del ángulo de fase de la componente de secuencia positiva a la frecuencia fundamental, el cual para el inicio del hundimiento de tensión presenta un transitorio abrupto con un pico de 1.5 [rad] el cual dura alrededor de 97.8 [ms], y cuando finaliza el hundimiento, el transitorio es más moderado porque presenta un pico de -0.694 [rad] y dura alrededor de 52.5 [ms] en llegar al 98% del valor de referencia del ángulo de fase.


Figura 44. Ángulo de fase de la componente fundamental – LMS



Escenario 2:

Ahora se procede a estudiar los resultados del algoritmo LMS ante la tensión de entrada del escenario 2 de prueba. Como se aprecia en la figura 45, la estimación de la magnitud de las componentes de secuencia no es la esperada ya que ante hundimientos de tensión severos como 0.3 pu en $t = 0.4$ [s] el algoritmo no responde con la velocidad de estimación suficiente como para estabilizarse antes de que ocurra el siguiente cambio de amplitud en $t = 1$ [s], es decir, el primer hundimiento dura 0.6 [s] y se espera que el algoritmo estime las componentes en un tiempo inferior a este.

Figura 45. *Magnitud de las componentes de secuencia – LMS*



Por otra parte, en la figura 46 se muestra que la frecuencia no es correctamente estimada durante el hundimiento de tensión ya que presenta un transitorio con un sobrepaso de 520% y adicionalmente tiene pequeñas oscilaciones de 2 [Hz] mientras se estabiliza. Por esta razón la magnitud de las componentes de secuencia no llega al valor esperado con rapidez. En comparación, los otros algoritmos analizados en este trabajo si realizan la estimación en un tiempo inferior antes de que ocurra el siguiente cambio de amplitud en $t = 1$ [s]. En la figura 47 se muestra la estimación

del ángulo de fase de la componente de secuencia positiva. El algoritmo no estima adecuadamente este parámetro ya que el tiempo que le toma en estabilizarse es muy grande (2 [s] aproximadamente), en contraste con los parámetros de la tensión de entrada.

Figura 46. *Frecuencia fundamental estimada – LMS*






Figura 47. *Ángulo de fase de la componente fundamental – LMS*



Escenario 3:


A continuación, se muestra la estimación de la magnitud de las componentes de secuencia del algoritmo ante un cambio de frecuencia en $t = 1$ [s] como esta descrito en el escenario 3 de simulación. El algoritmo tarda alrededor de 90.87 [ms] en llegar al 102% del valor de referencia de la magnitud de la componente de secuencia positiva.

Figura 48. *Magnitud de las componentes de secuencia – LMS*




Siguiendo con los resultados ante la variación de frecuencia descrita en el escenario 3 de simulación, en la figura 49 se muestra la estimación de la frecuencia fundamental. Esta es estimada correctamente por el algoritmo LMS y tarda 54.1 [ms] en llegar al 99.9% del valor de referencia de la frecuencia en estado estable (61 ± 0.061 [Hz]).

Figura 49. Frecuencia estimada – LMS



Por otra parte, en la figura 50 se presenta la estimación del ángulo de fase el cual es estimado correctamente, pero presenta un transitorio muy brusco con un valor pico de 1.52 [rad], y emplea 88.3 [ms] en llegar al 102% del valor de referencia del ángulo de fase.


Figura 50. Ángulo de fase de la componente fundamental – LMS




Escenario 4:

Se procede con el análisis del algoritmo LMS ante la tensión de entrada del escenario 4 el cual esta descrito en la sección 6.3. En la figura 51 se presenta la estimación de la magnitud de las componentes de secuencia. Como se puede observar, el algoritmo realiza una estimación errónea de las magnitudes las cuales se esperan que sean 0.862 pu de secuencia positiva y 0.182 pu de secuencia negativa durante el hundimiento de tensión, y en operación normal se espera que las magnitudes sean 1.001 y 0.016 pu de secuencia positiva y negativa respectivamente. Esto es debido a que el modelo de señal propuesto no está previsto para distorsión armónica.


Figura 51. *Magnitud de las componentes de secuencia – LMS*



Por otro lado, en la figura 52 se presenta la estimación de la frecuencia por parte del algoritmo, la cual es estimada correctamente y tarda 105 [ms] en llegar al 99.9% de su valor nominal.

Figura 52. *Frecuencia estimada – LMS*

Así como la magnitud de las componentes de secuencia, el algoritmo realiza una estimación errónea del ángulo de fase de la componente de secuencia positiva ante la señal de entrada, tal y como se muestra en la figura 53.

Figura 53. *Ángulo de fase de la componente fundamental – LMS*


6.4.4 Simulación ANF

En esta sección se muestra la simulación del algoritmo ANF ante cada uno de los escenarios de prueba definidos en la sección 6.3.


Escenario 1:

A continuación, se observa la estimación de la magnitud de las componentes de secuencia por parte de algoritmo ANF ante la tensión de entrada de la figura 6.3. Al observar la figura 54 se reconoce que el algoritmo estima correctamente la magnitud de las componentes ante el hundimiento de tensión y tarda alrededor de 15.2 [ms] en alcanzar el estado estable.


Figura 54. *Magnitud de las componentes de secuencia – ANF*



Por otra parte, en la figura 55 se muestra la estimación de la frecuencia fundamental ante la tensión de entrada. El algoritmo estima correctamente este parámetro y tarda 23.33 [ms] en llegar al 99.9% del valor de referencia (60 [Hz]). De acuerdo con los criterios, el valor pico que se presenta durante el transitorio está en un rango del 2.7% de la frecuencia fundamental nominal.


Figura 55. *Frecuencia fundamental estimada – ANF*

Por último, en la figura 56 se muestra la estimación del argumento de la componente fundamental y su error ante la tensión de entrada. Como se puede observar el argumento es estimado correctamente durante el hundimiento de tensión tardando 20.23 [ms] en llegar al 98% según el criterio de tiempo de establecimiento.

Figura 56. *Argumento de la componente fundamental y su error de estimación – ANF***Escenario 2:**


En este caso se muestra la estimación de la magnitud de las componentes de secuencia que realiza el algoritmo ante la tensión de entrada descrita en el escenario 2 de la sección 6.3. En la figura 57 se observa que el algoritmo realiza correctamente la estimación de la magnitud. En el primer cambio de amplitud, el cual es el más extremo de 1 a 0.3 en [pu], el algoritmo tarda alrededor de 100 [ms] en llegar al 98% del valor de referencia de la componente de secuencia.

Figura 57. Magnitud de las componentes de secuencia – ANF




Asimismo, en la figura 58 se muestra la frecuencia estimada por el algoritmo. Esta presenta un fuerte transitorio con un valor pico de 3.66 [Hz] con respecto al valor de referencia, en el primer cambio de amplitud la frecuencia tarda 600 [ms] en llegar al 99.9% del valor nominal.

Figura 58. Frecuencia estimada – ANF



En la figura 59 se muestra la estimación del argumento de la tensión de entrada y su error. Como se aprecia el algoritmo tarda 311.3 [ms] en estimar el argumento para el primer cambio de amplitud de 1 a 0.3 [pu].


Figura 59. *Argumento de la componente fundamental y su error – ANF*



Escenario 3:


Se procede con el análisis del tercer escenario definido en la sección 6.3 para el algoritmo ANF. En la figura 60 se presenta la estimación de la magnitud de las componentes secuencia ante una variación de frecuencia de 1 [Hz], el algoritmo responde correctamente y su estimación tiene variaciones que son del orden del 1.47% de su valor nominal, por lo tanto, se considera instantánea la estimación.

Figura 60. Magnitud de las componentes de secuencia – ANF




En la figura 61 se muestra la estimación de la frecuencia. Como se aprecia, el algoritmo calcula correctamente la variación de frecuencia con valor pico durante el transitorio del 100.05%, tardando alrededor de 27.23 [ms] en llegar al 99.9% del valor de referencia de la frecuencia.

Figura 61. Frecuencia fundamental estimada – ANF




Por otro lado, en la figura 62 se muestra la estimación del argumento de la componente fundamental y su error al ocurrir la variación en la frecuencia fundamental, el algoritmo es capaz de estimar correctamente el argumento de la componente fundamental para lo cual emplea 20.43 [ms] en llegar al 98% del valor de referencia.

Figura 62. *Argumento de la componente fundamental – ANF*




Escenario 4:

Ahora se procede con los resultados de simulación para el algoritmo ANF ante la tensión de entrada de la figura 17. En la figura 63, se presenta la estimación de la magnitud de las componentes de secuencia. El algoritmo responde como se esperaba, pues se filtran parte de los armónicos (rizo pico a pico de $4,11 \times 10^{-3}$ [pu]) en la magnitud. Con este rizo tarda 22.45 [ms] en llegar al 98% del valor de referencia de las magnitudes. Cabe mencionar que si la distorsión armónica es de mayor magnitud se va a distorsionar más la señal de salida del algoritmo.


Figura 63. *Magnitud de las componentes de secuencia – ANF*

De la misma forma, en la figura 64 se muestra la estimación de la frecuencia fundamental, en la cual se aprecia como se filtra el rizo producido por la distorsión armónica en la estimación. Aun cuando la frecuencia estimada tiene variaciones en un rango de 0.02 [Hz] esta tarda 27 [ms] en llegar al 99.9% del valor nominal.

Figura 64. *Frecuencia fundamental estimada – ANF*

Finalmente, en la figura 65 se muestra la estimación del argumento de la componente fundamental y su error. A partir de la figura del error se aprecia un rizo y de acuerdo con el criterio de tiempo de establecimiento el algoritmo emplea 20.29 [ms] en realizar la estimación.

Figura 65. *Argumento de la componente fundamental – ANF*



6.5 Análisis de resultados

En la tabla 3 se presentan los resultados para los criterios de evaluación obtenidos de las simulaciones realizadas en cada uno de los escenarios. Con el fin de realizar un análisis comparativo de los 4 algoritmos, en la tabla 4 se muestra una jerarquización cualitativa a partir del análisis cuantitativo de la tabla 3.

Tabla 3. Resultados de simulación para los parámetros de la componente fundamental

Algoritmo	Kalman			DDSRF-PLL			LMS			ANF		
Parámetro	t_{est} [ms]	sobrepaso (%)	EeEE	t_{est} [ms]	sobrepaso (%)	EeEE	t_{est} [ms]	sobrepaso (%)	EeEE	t_{est} [ms]	sobrepaso (%)	EeEE
Escenario 1												
V^+	11.47	0.8	$-2 * 10^{-4}$ [V]	15.6	4.035	$-4 * 10^{-4}$ [V]	66.4	3.657	$7 * 10^{-3}$ [V]	15.2	4.8	$4 * 10^{-3}$ [V]
V^-	18.29	1.652	$4 * 10^{-4}$ [V]	55.9	23.03	$5 * 10^{-4}$ [V]	139.8	34.96	$7 * 10^{-3}$ [V]	52.16	25.56	$5 * 10^{-4}$ [V]
Frecuencia	Instan	0	$9 * 10^{-7}$ [Hz]	42.23	20.47	$5.3 * 10^{-5}$ [Hz]	72.3	3.2	$2.6 * 10^{-4}$ [Hz]	23.33	2.73	$3.7 * 10^{-5}$ [Hz]
Argumento o ángulo +	14.76	10	$4.7 * 10^{-4}$ [rad]	17.5	17.16	$3.3 * 10^{-6}$ [rad]	97.8	49.75	$8.5 * 10^{-4}$ [rad]	20.23	14.78	$5.6 * 10^{-5}$ [rad]
Escenario 2												
V^+	14.8	4.584	$5 * 10^{-5}$ [V]	26.15	40.43	$1 * 10^{-7}$ [V]	No es veloz	No es veloz	No es veloz	100	13.77	$2 * 10^{-3}$ [V]
V^-	22.35	21.87	$-9.1 * 10^{-6}$ [V]	15.51	28.03	$6.3 * 10^{-6}$ [V]	No es veloz	No es veloz	No es veloz	22.8	23.31	$2.3 * 10^{-3}$ [V]
Frecuencia	167.3	2.9167	$1 * 10^{-5}$ [Hz]	22.99	51.8	$5 * 10^{-9}$ [Hz]	No es veloz	No es veloz	No es veloz	600	5.96	$7 * 10^{-3}$ [Hz]
Argumento o ángulo +	117.5	57.1	$3 * 10^{-4}$ [rad]	35.16	78.71	$3.8 * 10^{-7}$ [rad]	No es veloz	No es veloz	No es veloz	311.3	59.33	$3.42 * 10^{-3}$ [rad]
Escenario 3												
V^+	40	2.5	$22 * 10^{-5}$ [V]	Instan	-0.14	$6 * 10^{-7}$ [V]	90.87	9.26	$2.34 * 10^{-5}$ [V]	Insta	1.47	$5.6 * 10^{-7}$ [V]
V^-	Instan.	$6 * 10^{-3}$	$3.4 * 10^{-11}$ [V]	Instan	0.23	$-4.7 * 10^{-6}$ [V]	145.5	26.69	$9.79 * 10^{-5}$ [V]	Insta	0.9	$8.3 * 10^{-7}$ [V]
Frecuencia	84.45	0	$3.3 * 10^{-10}$ [Hz]	17.66	0.278	$-7.4 * 10^{-4}$ [Hz]	54.1	0	$9.4 * 10^{-7}$ [Hz]	27.43	0.05	$5.1 * 10^{-7}$ [Hz]
Argumento o ángulo +	44.57	5.198	$3.1 * 10^{-3}$ [rad]	Insta	0.77	$5.4 * 10^{-6}$ [rad]	88.3	49.78	$1.7 * 10^{-6}$ [rad]	20.43	4.54	$2.1 * 10^{-6}$ [rad]
Escenario 4												
V^+	11.8	0.8	$-2 * 10^{-4}$ [V]	34.84	6.09	0.01 [V]	Falla	Falla	Falla	22.45	4.8	$4 * 10^{-3}$ [V]
V^-	18.11	1.982	$4 * 10^{-4}$ [V]	33.24	24.7	0.01 [V]	Falla	Falla	Falla	52	25.56	$5 * 10^{-4}$ [V]
Frecuencia	Instan	0	$9 * 10^{-7}$ [Hz]	-	25.5	5 [Hz]	105	34.38	$-1.8 * 10^{-3}$ [Hz]	27	2.73	$3.7 * 10^{-5}$ [Hz]
Argumento o ángulo +	14.8	10.49	$9.2 * 10^{-4}$ [rad]	31.47	17.33	$1.9 * 10^{-2}$ [rad]	Falla	Falla	Falla	20.29	15.02	$5.17 * 10^{-4}$ [rad]

*Instan: La estimación realizada por el algoritmo tiene variaciones menores que la franja definida para el cálculo del tiempo de establecimiento, por lo tanto, la estimación se considera instantánea.

*No es veloz, significa que su respuesta no tiene la rapidez esperada por esto se considera que no alcanza a realizar la estimación.

*Falla: significa que el algoritmo no es capaz de estimar los parámetros de la señal de entrada

Para realizar el cálculo de los criterios de evaluación se utilizaron las ecuaciones descritas en la sección 6.2. Particularmente, para realizar el cálculo de los criterios de evaluación de desempeño para el argumento de la componente de secuencia positiva a la frecuencia fundamental (para el caso del Kalman, DDSRF-PLL, y ANF), se generó una señal ideal correspondiente al argumento, la cual se consideró para el cálculo del error de estimación mediante la diferencia de esta con el argumento estimado por el algoritmo.

Cabe resaltar que las señales estimadas en el escenario 4 para los algoritmos DDSRF-PLL y ANF son para la banda del $\pm 2\%$ en la salida del algoritmo debido a que en la estimación de los parámetros fundamentales se presenta un rizo causado por la distorsión armónica, y este será de mayor magnitud si la distorsión armónica se hace mayor en la tensión de entrada (tensión de la red).

Es de notar que para la estimación de la frecuencia se utilizó un criterio más estricto ($99.9 - 100.1$ [%]) para evaluar su desempeño, ya que para aplicaciones de control de sistemas de compensación de energía activa y reactiva, este parámetro es fundamental para su operación por lo mencionado en el criterio de tiempo de establecimiento para este parámetro.

Para el algoritmo LMS, en el escenario 2 se muestra “No es veloz”, esto significa que el algoritmo ante huecos de tensión menores a 0.6 pu, su respuesta a los mismos es muy lenta y no alcanza a realizar la estimación.

La palabra “falla” para el algoritmo LMS, se interpreta que no es capaz de estimar los parámetros de la señal de entrada ante distorsión armónica, lo anterior se hace evidente ya que el modelo de señal propuesto para el cálculo de los parámetros no considera este tipo de perturbación.

A partir de la tabla 3 se compararon los criterios descritos en la sección 6.2 para cada uno de los parámetros de la componente fundamental, y a partir de su análisis se definió el orden jerárquico que se muestra en la tabla 4.

Tabla 4. *Análisis comparativo de los algoritmos*

Parámetro	Estabilidad (%SP)	Velocidad de convergencia (t_{est})	Exacto y Robusto (EeEE)
Escenario 1			
V^+	Kalman > LMS $\approx$ DDSRF-PLL $\approx$ ANF	Kalman > ANF $\approx$ DDSRF-PLL > LMS	Kalman $\approx$ DDSRF-PLL > ANF $\approx$ LMS
V^-	Kalman > DDSRF-PLL $\approx$ ANF > LMS	Kalman > ANF $\approx$ DDSRF-PLL > LMS	Kalman $\approx$ DDSRF-PLL $\approx$ ANF > LMS
Frecuencia	Kalman > ANF $\approx$ LMS > DDSRF-PLL	Kalman > ANF > DDSRF-PLL > LMS	Kalman > DDSRF-PLL > ANF > LMS
Argumento o ángulo +	Kalman > ANF > DDSRF-PLL > LMS	Kalman > DDSRF-PLL $\approx$ ANF > LMS	DDSRF-PLL > ANF > Kalman $\approx$ LMS
Escenario 2			
V^+	Kalman > ANF > DDSRF-PLL	Kalman > DDSRF-PLL > ANF	DDSRF-PLL > Kalman > ANF
V^-	Kalman $\approx$ ANF > DDSRF-PLL	DDSRF-PLL > Kalman $\approx$ ANF	Kalman $\approx$ DDSRF-PLL > ANF
Frecuencia	Kalman > ANF > DDSRF-PLL	DDSRF-PLL > Kalman > ANF	DDSRF-PLL > Kalman > ANF
Argumento o ángulo +	Kalman $\approx$ ANF > DDSRF-PLL	DDSRF-PLL > Kalman > ANF	DDSRF-PLL > Kalman > ANF
Escenario 3			
V^+	DDSRF-PLL > ANF > Kalman > LMS	DDSRF-PLL = ANF > Kalman > LMS	DDSRF-PLL $\approx$ ANF > Kalman $\approx$ LMS
V^-	Kalman > DDSRF-PLL $\approx$ ANF > LMS	Kalman = DDSRF-PLL = ANF > LMS	Kalman > ANF > DDSRF-PLL > LMS
Frecuencia	Kalman = LMS > ANF > DDSRF-PLL	DDSRF-PLL > ANF > LMS > Kalman	Kalman > LMS $\approx$ ANF > DDSRF-PLL
Argumento o ángulo +	DDSRF-PLL > Kalman $\approx$ ANF > LMS	DDSRF-PLL > ANF > Kalman > LMS	DDSRF-PLL $\approx$ ANF $\approx$ LMS > Kalman
Escenario 4			
V^+	Kalman > ANF > DDSRF-PLL	Kalman > ANF > DDSRF-PLL	Kalman > ANF > DDSRF-PLL
V^-	Kalman > ANF $\approx$ DDSRF-PLL	Kalman > DDSRF-PLL > ANF	Kalman $\approx$ ANF > DDSRF-PLL
Frecuencia	Kalman > ANF > DDSRF-PLL > LMS	Kalman > ANF > LMS	Kalman > ANF > LMS > DDSRF-PLL
Argumento o ángulo +	Kalman > ANF > DDSRF-PLL	Kalman > ANF > DDSRF-PLL	Kalman $\approx$ ANF > DDSRF-PLL

En la tabla 4, se considera que cada parámetro de señal tiene la misma importancia al igual que cada escenario de simulación ya que este trabajo de investigación se enfoca en la comparación de los algoritmos ante hundimientos de tensión de corta duración, de esta forma se establece el siguiente análisis de resultados:

Para el escenario 1:

En base a lo mencionado, el algoritmo Kalman con filtro Butterworth establece su superioridad frente a los demás algoritmos para los criterios de evaluación de desempeño. Es decir,

es más veloz (el mayor tiempo de establecimiento en la estimación de los parámetros fue de 18.29 [ms]), estable (sobrepasos menores a 10%), exacto y robusto en la estimación de todos los parámetros de la componente fundamental excepto en el argumento.

Para los algoritmos DDSRF-PLL y ANF, se observa que tienen velocidad de convergencia semejantes en componentes de secuencia positiva (15.6 y 15.2 [ms], respectivamente), y negativa (55.2 y 52.16 [ms] respectivamente), excepto con la frecuencia, para la cual, el ANF es mejor con un tiempo de 23.33 [ms] y el DDSRF-PLL tiene un tiempo de 42.23 [ms]. Observando la estabilidad para la estimación de las componentes de secuencia y argumento, los dos algoritmos tienen resultados similares. En cuanto a la estimación de la frecuencia, el ANF presenta mejor estabilidad con 2.73% de sobrepaso, mientras el DDSRF-PLL con 20.47% de sobrepaso. En lo que respecta la exactitud y robustez, el DDSRF-PLL y ANF poseen capacidades semejantes.

Por otro lado, el algoritmo LMS comparado con los demás es inferior en exactitud y robustez. Respecto a la velocidad de convergencia, el LMS tiene el menor desempeño, ya que el parámetro que tiene menor tiempo de convergencia tarda 66.4 [ms], y el que más tarda en establecerse lo hace en 139.8 [ms] resultados más lentos a los presentados por los demás algoritmos. Finalmente, en cuanto a estabilidad, el LMS es semejante al ANF en cuanto a estimación de frecuencia y componente de secuencia positiva. Para la estimación de la componente de secuencia negativa y el argumento es el menos estable con sobrepasos de 34.96 y 49.75%, respectivamente.

Para el escenario 2:

En primera instancia, el algoritmo LMS no se presenta en los resultados de la tabla 4 para este escenario, debido a que este algoritmo realiza una lenta estimación de los parámetros en el intervalo de ocurrencia del hundimiento tardando un tiempo mayor (aproximadamente 2 [s]) con

respecto a la duración del evento considerado. En cuanto a la estabilidad, al observar la tabla 4 el algoritmo Kalman es el más estable, seguido del ANF y por último el DDSRF-PLL.

Sin embargo, el DDSRF-PLL es el más veloz en la estimación de todos los parámetros (excepto la frecuencia) con un tiempo promedio de 24.95 [ms], comparado con el tiempo promedio del Kalman de 80.48 [ms], y el del ANF que es de 285.52 [ms]. Respecto a la exactitud y robustez, comparado con los demás algoritmos, el DDSRF-PLL tiene el mejor desempeño, aunque eso no quiere decir que los demás algoritmos sean deficientes en este aspecto, pues de acuerdo con los criterios de desempeño, todos consiguen buenos resultados con un error en estado estable de un orden menor a 10^{-3} para todos los parámetros estimados.

Por otra parte, el Kalman tiene mejor desempeño que el ANF, ya que el ANF posee los mayores tiempos de establecimiento en todos los parámetros, su estabilidad es superada por los resultados del Kalman, y el error en estado estable está por el orden de 10^{-3} . Por lo tanto, entre los tres algoritmos funcionales para este escenario, el que tiene menor desempeño es el ANF.

Para el escenario 3:

De acuerdo con los resultados para este escenario, es complejo discriminar el desempeño de cada algoritmo de forma generalizada. Sin embargo, analizando la tabla 4 para cada parámetro estimado, con respecto a la componente de secuencia positiva se observa que, el DDSRF-PLL y el ANF son los más veloces (estimación instantánea), exactos (en el orden de 10^{-7}), robustos y estables (sobrepasos de 0.14% y 1.47%, respectivamente). Para el caso de la componente de secuencia negativa, el algoritmo Kalman presenta los mejores desempeños con una estimación instantánea y su error en estado estable y sobrepaso son aproximadamente cero. En cuanto a la frecuencia, cabe resaltar que el más rápido es el DDSRF-PLL, con un tiempo de 17.76 [ms], y respecto a la estabilidad, robustez y exactitud, el Kalman tiene el mejor desempeño en la variación

de frecuencia. Por último, el DDSRF-PLL es superior en la estimación del argumento de secuencia positiva de la componente fundamental, ya que presenta los mejores resultados pues su estimación es instantánea con sobrepaso de 0.77%, y un error en estado estable de $5.6 * 10^{-6}$.

Para el escenario 4:

Para este escenario, los resultados comparativos de los algoritmos son semejantes a los resultados del escenario 1. El algoritmo Kalman como era de esperarse, es superior en la estimación de los parámetros en cuanto a velocidad de convergencia (con un tiempo promedio de 11.18 [ms]), estabilidad (un sobrepaso promedio de 3.32%), exactitud y robustez (un error del orden de 10^{-4}), con respecto a los demás algoritmos. El desempeño sobresaliente de este algoritmo ante distorsión armónica en la señal de entrada se debe no solo a su modelo matemático sólido, sino por la función que realiza el filtro Butterworth de mitigar las componentes armónicas de mayor frecuencia a la fundamental. Por otra parte, aun cuando los algoritmos DDSRF-PLL y ANF presentan un rizo a su salida son incluidos en el análisis ya que los parámetros cumplen con el criterio de $\pm 2\%$, es decir, su estimación está en este rango. Cabe resaltar que los algoritmos DDSRF-PLL y ANF no están preparados para distorsión armónica como lo evidencian los resultados.

En cuanto al LMS, como se mencionó anteriormente, este no presenta una correcta estimación de los parámetros de la componente fundamental ante distorsión armónica, esto era de esperarse por el modelo de señal propuesto. Los resultados de simulación confirman lo dicho sobre el mismo. Adicionalmente, se debe mencionar que existen diferentes tipos de LMS, como el filtro de mínimos cuadrados recursivos estándar (RLS, por sus siglas en inglés) el cual según (Díaz y Ortiz, 2010) presentan mejores resultados en la estimación de parámetros de señales bajo ciertas condiciones. Cabe resaltar que el ANF se puede hacer más veloz (velocidad de convergencia)

mediante el ajuste del parámetro γ , pero su estabilidad se afecta, pues el algoritmo presenta transitorios más fuertes al manipular este parámetro.

En términos generales, al considerar que todos los parámetros y escenarios tienen la misma importancia, se puede afirmar que, el algoritmo más veloz en todos los escenarios es el DDSRF-PLL, con un tiempo total promedio de 23.21 [ms], seguido del Kalman con 36.19 [ms], el ANF con un tiempo de 82.16 [ms] y por último el LMS con 95.56 [ms]. Respecto a la estabilidad, el Kalman presenta el mejor desempeño con un sobrepaso promedio total de 7.49%, seguidamente el ANF con 12.83%, el DDSRF-PLL con 21.17% y el LMS con 23.52%. La velocidad en la estimación es importante porque es un parámetro de entrada para los sistemas de control para compensación de energía eléctrica. También se aclara que todos los argumentos estimados por los algoritmos corresponden a la componente de secuencia positiva a la frecuencia fundamental.

7. Conclusiones

Se ha realizado un análisis de desempeño de los algoritmos de sincronización Kalman extendido con filtro Butterworth, DDSRF-PLL, LMS estándar y ANF, en la estimación de las componentes de secuencia, frecuencia y argumento o ángulo de fase de la componente fundamental de señales eléctricas. Este análisis incluye un estudio mediante simulaciones en el software MATLAB/SIMULINK, para evaluar las características de desempeño descritas en la sección 6.3. De lo anterior se formulan las siguientes conclusiones generales y particulares:

- El algoritmo Kalman presentó el mejor desempeño ante hundimientos con desbalance en la magnitud de tensión y cambio en el ángulo de fase en la tensión trifásica. Es de resaltar su capacidad para estimar la frecuencia, pues lo hace instantáneamente y la rapidez para estimar los demás parámetros.

- Ante el hundimiento de tensión como el definido en el escenario 2, se resalta que el algoritmo DDSRF-PLL, en cuanto a la estimación de la frecuencia, tiene una velocidad de convergencia casi 8 veces más rápida que el Kalman, pero su estabilidad es menor porque en promedio presenta sobrepasos de 21.17%. Sin embargo, se podría implementar un filtro pasa bajas a su salida para mitigar ese bruceo transitorio. Considerando lo anterior, este algoritmo DDSRF-PLL se podría implementar en la sincronización de sistemas en los que se pueda presentar un hundimiento de tensión como el descrito en el escenario 2 de simulación por su rápida respuesta en la estimación de la frecuencia.

- Para fallas como el hundimiento descrito en el escenario 2, el algoritmo ANF no es el adecuado para la estimación de frecuencia, ya que su respuesta es muy lenta tanto que estaría fuera de una aplicación práctica, porque este parámetro es importante para sistemas de control de compensación de energía activa y reactiva.

- Ante una variación en la frecuencia de la tensión de la red como la descrita en el escenario 3, el DDSRF-PLL sigue siendo muy importante por la velocidad de estimación de la frecuencia.

- Debido a que el algoritmo LMS implementa dos modelos de señal acoplados, esto pudo influir en su desempeño comparado con los demás algoritmos, especialmente en el escenario 2, ya que este algoritmo ante hundimientos menores a 0.7 pu su respuesta se hace lenta y se intensifica cuando el hundimiento tiene mayor magnitud.

- El algoritmo Kalman tiene un desempeño óptimo en la estimación de todos los parámetros cuando se presenta distorsión armónica, con respecto a los algoritmos analizados.

Trabajos futuros

Son muchas las aplicaciones en las cuales podría encaminarse este trabajo. Algunas de ellas se mencionan a continuación:

- Implementación del modelo de señal propuesto en el algoritmo LMS, en el algoritmo recursivo RMS, con el fin de evaluar su desempeño, ya que de acuerdo con [11], el RMS presenta mejores resultados en la estimación de los parámetros.

- Proponer un modelo de señal extendido para el LMS y RMS que considere distorsión armónica a partir del modelo propuesto para el LMS.

- Estudio e implementación de algoritmos de sincronización híbridos, es decir, que se combinen para obtener mejores características de desempeño.

- Estudiar e implementar un modelo de señal o filtro para que los algoritmos DDSRF-PLL sean competitivos ante distorsión armónica en la señal de tensión.

Referencias Bibliográficas

- Camacho Antonio, Castilla Miguel, Miret Jaume, C. Vasquez Juan, and Alarcón-Gallo Eduardo. (april 2013). Flexible Voltage Support Control for Three-Phase Distributed Generation Inverters Under Grid Fault” IEEE transactions on industrial electronics, 60 (4).
- Chroma ANC INC. (January 2012). Programmable AC source 61511/61512 user’s manual.
- Davood Yazdani, Alireza Bakhshai, Geza Joos, and M. Mojiri. (4 de julio del 2019). A Nonlinear Adaptive Synchronization Technique for Grid-Connected Distributed Energy Sources. IEEE transactions on power electronics, 23 (4).
- Díaz Idania y Ortiz Hugo. (2010). Estimación de parámetros de señales eléctricas: Estudio e implementación de algoritmos basados en filtrado adaptativo. Trabajo de grado de pregrado. Escuela de ingenierías eléctrica, electrónica y telecomunicaciones. Universidad Industrial de Santander.
- Duarte Cesar. (2004). Técnicas de Procesamiento de Señales Para la Monitorización de la Calidad de la Energía Eléctrica. Trabajo de Título de Magíster en Potencia Eléctrica. Departamento de Ingenierías Eléctrica Electrónica y Telecomunicaciones, Universidad Industrial de Santander. 28-34, 37-45.
- Flórez Wilmer y Gonzalo Franklin. (2014). Análisis comparativo entre estrategias para la estimación en el dominio del tiempo de parámetros de señales eléctricas distorsionas y/o desequilibradas. Tesis de pregrado. Escuela de ingenierías eléctrica, electrónica y telecomunicaciones. Universidad Industrial de Santander.

- G. Welch y G. Bishop. (2001). An introduction to the kalman filter. University of North Carolina at Chapel Hill. Department of Computer Science. Available: <http://info.acm.org/pubs/toc/CRnotice.html>
- Haykin Simon. (2002). Adaptive Filter Theory. Prentice Hal, Inc. Upper Saddle River, New Jersey. 4-17, 27-28, 94-108, 231-238, 311-312, 436- 446, 448-451, 463, 470-485, 496-501.
- IEEE 1159 standards association. (2019). Recommended practice for monitoring electric power quality. New York.
- J. Rodriguez, A. Lopes, L. Miranda, C. Gouveia, C. Moreira y J. Pecas Lopes. (2018). The role of Low-Voltage-Ride-Through capability of Distributed Energy Resources for the mitigation of voltage sags in Low Voltage distribution grids. Faculty of Engineering. University of Porto. Portugal.
- M. Bollen and I. Yu-Hua Gu. (2006). Signal Processing of Power Quality Disturbances. John Wiley & sons, Inc, 163-180, 254-275, 277-315.
- M. Mojiri and A. Bakhshai. (2004). An adaptive notch filter for frequency estimation of a periodic signal. IEEE Trans. Automat. Control, 49 (2), 314–318.
- M. Mojiri and A. Bakhshai. (April 2007). Estimation of n frequencies using adaptive notch filter. IEEE Trans. Circuits Syst. II. 54 (4), 338–342.
- M. Mojiri, M. Karimi-Ghartemani, and A. Bakhshai. (January 2007). Time domain signal analysis using adaptive notch filter. IEEE Trans. Signal Processing, 55 (1), 85–93.

- Manrique Cristián y Plata Yiris. (2019). Control de sistemas fotovoltaicos conectados a la red ante caídas de tensión de corta duración. Tesis de pregrado. Escuela de ingenierías eléctrica, electrónica y telecomunicaciones. Universidad Industrial de Santander.
- Mantilla Villalobos María A. (2016). Control de generadores fotovoltaicos con funciones de filtrado activo en sistemas trifásicos distorsionados y desequilibrados. Tesis doctoral. Escuela de ingenierías eléctrica, electrónica y telecomunicaciones. Universidad Industrial de Santander.
- Miodrag D. Kušljević. (june 2008). A Simple Recursive Algorithm for Simultaneous Magnitude and Frequency Estimation. IEEE transactions on instrumentation and measurement, 57 (6).
- Mohammad Qasim, Matthew Overlin, Colm O'Rourke y James Kirtley. (4 de diciembre del 2019). A geometry interpretation of reference frames and transformations: dq0, Clarke, and Park. IEEE transactions on energy conversión, 34 (4).
- Munoz-Hernandez, Diaz-Sanchez, J. G. Hernandez-Delgado, C. A. Vega-Lebrun. (2009). Estimating the frequency variation of the Mexican grid by Kalman filtering. International Conference on Electrical, Communications, and Computers.
- N.G. Hingorani. (1995). Introducing Custom Power. Spectrum IEEE, vol. 32.
- Nilanjan Mukherjee, Dipankar De, Neha Nandagaoli. Effect of Sudden Variation of Grid Voltage in Primary Frequency Control Application Using Converter Based Energy Storage Systems for Weak Grid Systems. assigned jointly to the European Power Electronics and Drives Association & the Institute of Electrical and Electronics Engineers (IEEE).

Ogata Katsuhiko. (2010). ingeniería de control moderna. 5 edición Pearson. Madrid. España

Oppenheim Alan V., Willsky Alan S. y Nawad S.Hamid. (1997). Señales y sistemas 2da. Ed.
Instituto de Tecnología de Massachusetts, y Universidad de Boston.

Parra Jorge y Toro Humberto. (2009). Estudio de la distorsión armónica y factor de potencia en la
red de alimentación eléctrica de una máquina papelera. Trabajo de grado de pregrado.
Universidad autónoma del occidente. Santiago de Cali.

Petit Johan. (2007). Control de filtros activos de potencia para la mitigación de armónicos y mejora
del factor de potencia en sistemas desequilibrados. Departamento de Ingeniería Eléctrica.
Universidad Carlos III de Madrid.

R. E. Kalman. (1960). A new approach to linear filtering and prediction problems. Transaction of
the ASME Journal of basic engineering. 82 (series D), 35-45.

Renewable Energy Policy Network for the 21st Century (REN21). (2020). Renewable Global
Status Report.

Resolución CREG 025. (1995). Código de redes como parte del reglamento de operación del
sistema eléctrico colombiano.

Serrano Domínguez Daniel. (julio 2014). Análisis comparativo de Técnicas de Sincronización con
la red eléctrica. Proyecto fin de carrera. Escuela superior de ingenieros. Universidad de
Sevilla.

- Y. Bae, T. Vu and R. Kim. (Sept. 2013). Implemental Control Strategy for Grid Stabilization of Grid-connected PV System Based on German Grid Code in Symmetrical Low-to-Medium Voltage Network. IEEE Transactions on Energy Conversion, 28(3), 619-631.
- Yang Y, Blaabjerg H. F. Wang and M. G. Simões. (2016). Power control flexibilities for grid-connected multi-functional photovoltaic inverters. IET Renewable Power Generation, 10(4), 504-513.