



**UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERIA ELÉCTRICA**

**PREDICCIÓN DE LA DEMANDA DE POTENCIA ELÉCTRICA DE METRO
S.A. EN TIEMPO REAL, MEDIANTE LA APLICACIÓN DE REDES
NEURONALES.**

**MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL
ELECTRICISTA**

CRISTIÁN PABLO REYES MOLINA

**PROFESOR GUÍA:
AUGUSTO LUCERO ALDAY**

**PROFESORES MIEMBROS DE LA COMISIÓN
CONRAD ZIEBOLD VAN AKEN
NELSON MORALES OSORIO**

**SANTIAGO DE CHILE
AGOSTO 2012**

PREDICCIÓN DE LA DEMANDA DE POTENCIA ELÉCTRICA DE METRO S.A. EN TIEMPO REAL, MEDIANTE LA APLICACIÓN DE REDES NEURONALES

El objetivo general del presente trabajo de título es diseñar e implementar un modelo matemático que permita realizar predicciones de la demanda de potencia eléctrica de Metro S.A. en tiempo real. El software obtenido permitirá predecir la demanda de potencia eléctrica en un instante de tiempo a futuro, y con esta información se podrá efectuar un control de demanda más eficiente del que se lleva a cabo hoy en día en Metro S.A.

Metro de Santiago posee 5 líneas en operación hoy en día, las cuales transportan una cantidad considerable de pasajeros a lo largo del día. En horario punta en la tarde, entre las 18:00 y las 20:00 hrs se efectúa el control de demanda de potencia eléctrica, mediante observación del registrador de consumo con acciones manuales para controlarla.

En este escenario, se ha desarrollado un software aplicado en Matlab, que entrena un conjunto de redes neuronales con la información de demanda de potencia eléctrica de Metro a lo largo de 1 año, información entregada por el sistema SCADA de Metro, y luego de la validación de cada red permite realizar predicciones de la demanda de potencia eléctrica con una certeza adecuada para los fines de control buscados.

Los resultados obtenidos mediante el entrenamiento de las redes neuronales permiten concluir que las predicciones dependen directamente del tamaño del intervalo de tiempo que se quiere predecir. También se tuvo una dependencia de las predicciones respecto del sistema que se estudiaba. Así, mientras mayor fue la disgregación de las variables del sistema dinámico a estudiar, mejores fueron las predicciones de las redes.

De esta forma, se separó el sistema dinámico de Metro S.A. en dos subsistemas, el SEAT (Subestación de alta tensión, L1, L2, L5) y el CDC-Vicente Valdés (Centro de Distribución de Carga, L4, L4A), debido a que poseen alimentación eléctrica y consumos distintos. Para cada sistema se entrenaron 24 redes neuronales, que predicen 5 minutos a futuro, para los 24 instantes de tiempo existentes cada 5 minutos entre las 18:05 y las 20:00 hrs.

Como producto del estudio se entrega un software que utiliza las 48 redes neuronales entrenadas con la dinámica eléctrica de Metro S.A. y mediante la supervisión de las variables eléctricas que realiza el sistema SCADA de Metro permite realizar predicciones acertadas dentro del rango de horario de hora punta para cualquier día de semana del año actual.

Se concluye que con la ayuda del software existirá la posibilidad de realizar un control de demanda de potencia eléctrica de Metro más eficiente, el cual permita automatizar el control de demanda en tiempo real de la variable potencia eléctrica de Metro S.A.

TABLA DE CONTENIDO

PREDICCIÓN DE LA DEMANDA DE POTENCIA ELÉCTRICA DE METRO S.A. EN TIEMPO REAL, MEDIANTE LA APLICACIÓN DE REDES NEURONALES		2
1.	INTRODUCCIÓN	9
2.	REVISIÓN BIBLIOGRÁFICA	11
2.1.	SISTEMA ELÉCTRICO.....	11
2.1.1.	Tracción eléctrica.....	12
2.1.1.1.	Campos de aplicación	13
2.1.2.	Motores eléctricos	14
2.1.2.1.	Motores de corriente continua.....	14
2.1.2.1.1.	Características del motor C.C. conexión serie	15
2.1.2.2.	Motores de corriente alterna	18
2.1.2.2.1.	Modelo equivalente monofásico del motor de inducción	19
2.1.2.3.	Características de motores utilizados en transporte	24
2.1.2.3.1.	Condiciones de trabajo.....	24
2.1.2.3.2.	Conexión de motores en tracción eléctrica	26
2.1.3.	Sistemas de tracción.....	27
2.1.3.1.	Aspectos sobre alimentación eléctrica de sistemas ferroviarios de transporte urbano.	27
2.1.3.2.	Ubicación de subestaciones de tracción en una línea de metro (Método clásico)	29

2.1.3.3.	Ubicación de subestaciones de tracción en una línea de metro (Por simulación de la marcha de un tren).....	35
2.1.3.3.1.	Ecuación dinámica.....	35
2.1.3.3.2.	Sistema discreto.....	36
2.1.3.3.3.	Fuerza motriz (Trenes con motores de corriente continua).....	37
2.1.3.3.3.1.	Fuerza motriz en función de la corriente.....	37
2.1.3.3.3.2.	Corriente de un motor en función del tiempo.....	37
2.1.3.3.3.3.	Fuerza motriz en función del tiempo.....	38
2.1.3.3.4.	Fuerza de resistencia al rodado.....	39
2.1.3.3.5.	Ejemplo de simulación.....	39
2.2.	PREDICCIÓN DE SERIES DE TIEMPO.....	44
3.	MODELACIÓN DE REDES NEURONALES.....	70
3.1.	METODOLOGÍA.....	70
3.2.	MODELO DE RED NEURONAL.....	74
3.3.	SIMULACIONES.....	82
3.3.1.	Datos de entrada.....	82
3.3.2.	Resultados para las predicciones del año 2010.....	84
3.3.2.1.	Centro de Distribución de Carga – Vicente Valdés (CDC-VV), año 2010.....	85
3.3.2.1.1.	Predicción a las 18:30 hrs.	85
3.3.2.2.	Subestación de Alta Tensión (SEAT), año 2010.	93
3.3.2.2.1.	Predicción a las 19:00 hrs.	93

3.3.3.	Predicciones horario punta 2012.....	96
3.3.3.1.	SEAT, año 2012.....	96
3.3.3.1.1.	Predicción a las 18:05 hrs.	97
3.3.3.1.2.	Predicción a las 18:10 hrs.	100
3.3.3.1.3.	Predicción a las 18:15 hrs.	101
3.3.3.1.4.	Predicción a las 18:20 hrs.	102
3.3.3.1.5.	Predicción a las 18:25 hrs.	102
3.3.3.1.6.	Predicción a las 18:30 hrs.	103
3.3.3.1.7.	Predicción a las 18:35 hrs.	103
3.3.3.1.8.	Predicción a las 18:40 hrs.	104
3.3.3.1.9.	Predicción a las 18:45 hrs.	104
3.3.3.1.10.	Predicción a las 18:50 hrs.	105
3.3.3.1.11.	Predicción a las 18:55 hrs.	105
3.3.3.1.12.	Predicción a las 19:00 hrs.	106
3.3.3.1.13.	Predicción a las 19:05 hrs.	106
3.3.3.1.14.	Predicción a las 19:10 hrs.	107
3.3.3.1.15.	Predicción a las 19:15 hrs.	107
3.3.3.1.16.	Predicción a las 19:20 hrs.	108
3.3.3.1.17.	Predicción a las 19:25 hrs.	108
3.3.3.1.18.	Predicción a las 19:30 hrs.	109
3.3.3.1.19.	Predicción a las 19:35 hrs.	109

3.3.3.1.20.	Predicción a las 19:40 hrs.	110
3.3.3.1.21.	Predicción a las 19:45 hrs.	110
3.3.3.1.22.	Predicción a las 19:50 hrs.	111
3.3.3.1.23.	Predicción a las 19:55 hrs.	111
3.3.3.1.24.	Predicción a las 20:00 hrs.	112
3.3.3.2.	CDC-VV, año 2012.....	112
3.3.3.2.1.	Predicción a las 18:05 hrs.	112
3.3.3.2.2.	Predicción a las 18:10 hrs.	113
3.3.3.2.3.	Predicción a las 18:15 hrs.	113
3.3.3.2.4.	Predicción a las 18:20 hrs.	114
3.3.3.2.5.	Predicción a las 18:25 hrs.	114
3.3.3.2.6.	Predicción a las 18:30 hrs.	115
3.3.3.2.7.	Predicción a las 18:35 hrs.	115
3.3.3.2.8.	Predicción a las 18:40 hrs.	116
3.3.3.2.9.	Predicción a las 18:45 hrs.	116
3.3.3.2.10.	Predicción a las 18:50 hrs.	117
3.3.3.2.11.	Predicción a las 18:55 hrs.	117
3.3.3.2.12.	Predicción a las 19:00 hrs.	118
3.3.3.2.13.	Predicción a las 19:05 hrs.	118
3.3.3.2.14.	Predicción a las 19:10 hrs.	119
3.3.3.2.15.	Predicción a las 19:15 hrs.	119

3.3.3.2.16.	Predicción a las 19:20 hrs.	120
3.3.3.2.17.	Predicción a las 19:25 hrs.	120
3.3.3.2.18.	Predicción a las 19:30 hrs.	121
3.3.3.2.19.	Predicción a las 19:35 hrs.	121
3.3.3.2.20.	Predicción a las 19:40 hrs.	122
3.3.3.2.21.	Predicción a las 19:45 hrs.	122
3.3.3.2.22.	Predicción a las 19:50 hrs.	123
3.3.3.2.23.	Predicción a las 19:55 hrs.	123
3.3.3.2.24.	Predicción a las 20:00 hrs	124
4.	CONCLUSIONES Y RECOMENDACIONES.....	125
5.	BIBLIOGRAFÍA	129

1. INTRODUCCIÓN

En sus 43 años de funcionamiento, Metro S.A. se ha convertido en el eje estructurante del transporte público de la capital.

El rol que cumple Metro de Santiago en el transporte público es clave, habiendo transportado aproximadamente 640 millones de pasajeros en el año 2011. La empresa cuenta con 103,6 kilómetros (distribuidos en Línea 1, Línea 2, Línea 4, Línea 4A y Línea 5), una flota de 967 coches, 108 estaciones y 4 talleres. (METRO S.A., 2011)

En el año 2011 la afluencia de pasajeros en la red alcanzó a 640 millones de viajes, lo que significa un aumento de 3,1% respecto al año 2010, explicado principalmente por la inauguración en el mes de Febrero de 2011 del segundo tramo de la Línea 5 en dirección a Maipú.

Claramente el Metro es esencial en el transporte diario de pasajeros de nuestra capital. Posee una demanda de pasajeros altísima, en particular en el horario punta de la tarde, por esta razón el servicio en ésta hora del día debe ser lo más eficiente dentro de las posibilidades de operación que se poseen.

Por razones de eficiencia se realiza un control de la demanda de potencia eléctrica, consumida por Metro en el horario punta, definido por la Comisión Nacional de Energía en el informe Técnico Definitivo emitido por dicha institución en Octubre del año 2011 (Comisión Nacional de Energía, 2011)

En estas condiciones, la potencia demandada por Metro S.A. es controlada entre las 18:00 y las 20:00 hrs para que no supere ciertos niveles establecidos por personal interno en Metro. El control principal de demanda de potencia se realiza desconectando cargas de alumbrado y disminuyendo la velocidad de los trenes que circulan por las diversas líneas de Metro en el horario punta tarde. Con esto, se logra disminuir la demanda de potencia eléctrica en el intervalo horario definido y así se logra no sobrepasar la potencia contratada y la energía proyectada.

La posibilidad de desarrollar un trabajo de investigación que permita apoyar a la eficiencia del medio de transporte más importante de Santiago, y que los beneficios sean aumentar la eficiencia de modo que Metro entregue mejor calidad de servicio, es la razón principal de haber formulado este trabajo de título.

Así nace el objetivo principal de éste trabajo de investigación, el cual consiste principalmente en diseñar e implementar un modelo matemático que permita realizar predicciones de la demanda de potencia eléctrica de Metro S.A. en el horario punta.

La hipótesis planteada es que si se posee información futura de cómo se comportará la variable potencia eléctrica demandada en un instante a futuro, entonces se podrá discriminar cuando efectuar control de velocidad y cuando no realizarlo, en base a las predicciones obtenidas del software.

Para esto, se utilizará las redes neuronales multicapa, modelo matemático del cerebro humano el cual permite entre otras cosas, realizar predicciones de series temporales en base a acontecimientos pasados. Los acontecimientos o historia de la dinámica eléctrica de Metro se obtendrá del sistema SCADA (Supervisory Control and Data Acquisition) de Metro que monitorea la potencia demandada minuto a minuto a todo momento, información que servirá para el entrenamiento que realizará el software Matlab, mediante un código que permita tomar esta información y enseñársela a las redes para que luego sean capaces de predecir el comportamiento dinámico de Metro S.A.

Los resultados del entrenamiento de las redes neuronales, más la explicación de la metodología utilizada y la teoría eléctrica y matemática utilizada, serán la base de los capítulos que forman parte importante de este trabajo de título.

2. REVISIÓN BIBLIOGRÁFICA

2.1.SISTEMA ELÉCTRICO

El sistema eléctrico de Metro S.A. tiene como finalidad abastecer de energía a todos los consumos de electricidad que se tengan en las instalaciones de la empresa. En particular, se tendrán dos tipos de consumo, los cuales permitirán a Metro S.A. realizar su misión como empresa.

Para iluminar cada estación de las diferentes líneas, energizar sus escaleras mecánicas, sus ascensores y energizar todo equipo no relacionado con el movimiento de los trenes, Metro posee Subestaciones de Alumbrado y Fuerza (SAF) ubicadas en las estaciones.

Las distintas Subestaciones de Alumbrado y Fuerza tienden a ser, en general, muy similares en sus valores de potencia nominal. Esto se debe principalmente a que sus cargas no crecerán de forma sustantiva a lo largo del tiempo.

El dimensionamiento de cada SAF se realizó conforme a los equipos existentes en las estaciones (escaleras mecánicas, ventiladores, etc.), dejando una reserva. Se estima 350 kVA para estaciones terminales y de combinación y de 250 kVA para el resto (Metro S.A., 2011).

Para alimentación en tracción, es decir, para realizar el movimiento de los trenes, el Metro dispone de Subestaciones de Rectificación (SER), también llamadas Subestaciones de Tracción.

El dimensionamiento de cada SER correspondiente a una línea en particular depende de muchas variables, las cuales apuntan principalmente a la capacidad que debe tener el sistema, de alimentar con energía eléctrica, a la cantidad de trenes que se tendrán en la línea a la hora de demanda máxima de pasajeros, en el tramo de la línea más cargado, y bajo criterios de seguridad y suficiencia de un sistema eléctrico de tracción.

2.1.1. Tracción eléctrica

La palabra tracción tiene relación directa con el arrastre, es decir, con la acción de provocar un movimiento en un determinado objeto, ya sea vertical u horizontal, cambiando su energía cinética.

Si el cuerpo involucrado debe ser llevado desde A hasta B, su energía cinética debe ser alterada, y para esto se hace necesaria la acción de una fuerza que efectúe un trabajo sobre este cuerpo. En la Ilustración 1 se muestra la situación anterior con la definición matemática del trabajo necesario para realizar dicho movimiento.




Ilustración 1 – Trabajo efectuado por una fuerza para provocar un movimiento

La fuerza F incluye todas las fuerzas presentes actuando sobre el cuerpo que se dispondrá en movimiento. La distancia S es la línea trazada que describe el movimiento del cuerpo desde A hasta B.

Para efectuar el trabajo T recién descrito, se necesita de un dispositivo que tenga la capacidad de llevarlo a cabo. En el caso de la tracción eléctrica, el dispositivo capaz de hacerlo es el motor eléctrico.

Existen diversos tipos de motores eléctricos, con distintas capacidades de realizar trabajo. Además el uso que se les puede dar es muy amplio, sin embargo a la hora de clasificarlos de forma general, sobresalen dos clases de motores: Motor eléctrico de corriente continua y motor eléctrico de corriente alterna.

2.1.1.1. Campos de aplicación

Dentro de las actividades del ser humano, la tracción eléctrica se ha integrado de manera significativa. La posibilidad de realizar un trabajo mediante energía eléctrica es de mucha utilidad para el hombre, principalmente por la eficiencia que se ha logrado en la conversión electromecánica de la energía, como también por el bajo impacto medioambiental que posee el uso de esta energía en comparación con los combustibles derivados del petróleo.

Existen ambientes de trabajo donde la tracción eléctrica es uno de los medios básicos de transporte, por ejemplo: En minas profundas se usan locomotoras eléctricas debido a que no producen humos contaminantes; En minas no subterráneas, cuando se emplean locomotoras muy pesadas, éstas pueden ser diesel o diesel eléctricas y no sólo eléctricas; En minas gaseosas se usan locomotoras con acumuladores (baterías) y en minas donde no existe peligro de explosión de gases, se pueden emplear locomotoras alimentadas con conductor aéreo.

En muchas empresas de diversos rubros productivos se utiliza tracción eléctrica en los vehículos de transporte interno, también en vehículos eléctricos como automóviles y minibuses, industria ya desarrollada gracias a los adelantos en la tecnología de acumuladores, aunque no se emplean masivamente.

Como medio de transporte urbano, y desde hace décadas se utilizan móviles accionados a través de la tracción eléctrica, ya sea aplicada a ferrocarriles, metro, metro ligero, tranvías, monorraíles, trolebuses ó buses guiados.

Considerando lo anterior, los campos de aplicación de la tracción eléctrica son muy amplios, y con una penetración considerable en las distintas actividades de la economía global. Estos pueden ser clasificados generalmente en dos ítems:

- Aplicaciones industriales y de transporte menor: En éste tópico se cuentan las Máquinas herramientas; Chancadoras o trituradoras; Puentes grúa; Ascensores; Escaleras mecánicas, y Aplicaciones mineras.
- Aplicaciones en transporte masivo: Dentro del transporte masivo se tiene los tranvías; Metro; Ferrocarriles; Trolebuses, y monorraíles.

2.1.2.Motores eléctricos

2.1.2.1. Motores de corriente continua

La primera máquina desarrollada para aplicaciones de potencia fue la máquina de corriente continua. La razón de ello fue que en un principio no se pensó que la corriente alterna tuviera las ventajas que hoy se le conocen, debido a que no se contaba con la electrónica de potencia.

La primera máquina de corriente continua fue creada por el belga Gramme alrededor de 1860. Posteriormente, el físico W. Siemens y otros, contribuyeron al desarrollo de éstas máquinas realizando rectificaciones en su construcción, hasta llegar a la máquina de CC que se conoce hoy (Lucero Alday, 2009).

Este tipo de máquinas requiere de mayor mantenimiento y a la vez tiene un mayor volumen y peso por kilo-watt de potencia. No obstante, la máquina de CC tiene aplicaciones

múltiples, especialmente como motor, debido principalmente al amplio rango de velocidades, a su característica de torque-velocidad variable, constante o bien una combinación ideada por tramos, por su rápida aceleración, desaceleración y cambio de sentido de giro, por último la posibilidad de frenado regenerativo.



Ilustración 2 – Motor de corriente continua (C.C.)

2.1.2.1.1. Características del motor C.C. conexión serie

La siguiente figura muestra el circuito equivalente del motor serie, donde se tiene:

V_g = Fuente de alimentación

E_a = Voltaje generado en la armadura

R_a = Resistencia del enrollado de armadura

I_a = Corriente de armadura

V_a = Voltaje de armadura

R_c = Resistencia del enrollado de campo

I_c = Corriente por el enrollado de campo

n = Velocidad del rotor

R_r = Resistencia variable (reóstato), que normalmente se conecta para controlar I_c .




Ilustración 3 – Circuito equivalente de un motor serie de corriente continua

Las ecuaciones asociadas a los circuitos de armadura y campo son:

$$\begin{aligned}I_g &= I_c = I_a \\V_g &= (R_c + R_r) \cdot I_a + V_a \\E_a &= V_a - R_a \cdot I_a\end{aligned}$$

La ecuación que relaciona las variables eléctricas y magnéticas es:

$$E_a = K_e \cdot n \cdot \phi$$

Adicionalmente se tiene:

$$\begin{aligned}E_a &= G \cdot w_r \cdot I_c \\T &= G \cdot I_c \cdot I_a = K_T \cdot \phi \cdot I_a\end{aligned}$$

La curva Torque – Velocidad del motor en conexión serie se muestra en la Ilustración 4.

La forma de la curva en este caso se tiene considerando:

$$T = G \cdot I_c \cdot I_a = G \cdot I_a^2$$

$$V_g = R \cdot I_a + E_a + R_a \cdot I_a$$

$$E_a = G \cdot w_r \cdot I_a$$

$$I_a = \frac{V_g}{(R + G \cdot w_r + R_a)}$$

$$R = R_c + R_r$$

$$\therefore T = \frac{G \cdot V_g^2}{(R + G \cdot w_r + R_a)^2}$$

Con las ecuaciones anteriores es posible calcular el torque de partida para este motor, además es posible determinar que la curva tiene un par de asíntotas que corresponden a

$$w_r = \frac{(R_a + R_c)}{G}$$

Y al eje $T = 0$. Esto significa que el motor serie no tiene transición de motor a generador y si el motor se hace operar en vacío (sin carga mecánica) se embala.




Ilustración 4 – Curva Torque – Velocidad de un motor serie.

Las ecuaciones que definen al motor de corriente continua, conexión serie, permiten analizar la potencia que demandará el motor del sistema eléctrico de tracción.

2.1.2.2. Motores de corriente alterna

Al hablar de motores de corriente alterna en tracción eléctrica, se hace referencia a la tracción asíncrona. La tracción asíncrona yace hace más de un siglo, ya en 1903 un automotor alemán operó un trayecto experimental cerca de Berlín, alcanzando los 210 km/hr con tracción asíncrona.

En 1879 Werner Von Siemens presentó su primera locomotora eléctrica y se comenzó a experimentar con el motor asíncrono trifásico, de construcción sencilla e ideal para fines de tracción, motor de inducción de jaula de ardilla.

Pero, definitivamente este sistema no logró imponerse, pese a su adopción pasajera en Suiza e Italia, porque requería una catenaria complicada, por lo menos bifásica y porque incluso con gran despliegue técnico no admitía sino muy poco en cuanto a regulación de velocidad.

Las máquinas asíncronas o de inducción, son en general de simple construcción, de bajo costo de fabricación y mantenimiento, y además, gracias a los avances en electrónica de potencia, los métodos de control son cada vez más sofisticados y precisos lo que permite que el motor de inducción reemplace frecuentemente al motor de corriente continua en aplicaciones industriales (correas transportadoras, ascensores, etc.).

La operación usual de la máquina de inducción es como motor, cuyo funcionamiento consiste en alimentar el enrollado del estator desde una fuente trifásica para así producir un campo magnético rotatorio. Este campo magnético gira con una velocidad síncrona (ω_s) de acuerdo con la frecuencia eléctrica de la alimentación e induce corrientes en el rotor mediante inducción. Gracias a las corrientes de estator y rotor es posible generar torque motriz en el eje de la máquina.

Existen también diseños especiales de motores de inducción, útiles para determinadas aplicaciones. Por ejemplo, se fabrican motores con doble jaula o con barras profundas, que permiten lograr un elevado torque de partida y baja corriente de partida, debido a que el transitorio de arranque de alta frecuencia en el rotor provoca una alta resistencia retórica (efecto pelicular). También se construyen motores de rotor bobinado, los que se usan cuando las condiciones de partida resultan severas, pues permiten adicionar resistencias en serie con los enrollados del rotor, para lo cual dicha maquina debe disponer de anillos rozantes. No obstante, también estos tipos de motores están siendo reemplazados por motores de jaula de ardilla controlados electrónicamente.

2.1.2.2.1. Modelo equivalente monofásico del motor de inducción

Una máquina de inducción corresponde a un sistema trifásico equilibrado, por lo cual su desempeño es posible de caracterizar a través de un circuito equivalente por fase.

Dado que la máquina funciona a través del principio de inducción, su circuito equivalente es muy similar al de un transformador monofásico, considerando el estator como el primario, y el rotor como el secundario. La diferencia con respecto al transformador es que las frecuencias de las variables eléctricas inducidas en el rotor (f_r) son distintas a las del estator (f), por lo cual es transformador, que es un dispositivo estático, corresponde a un caso particular en que la máquina de inducción está detenida, es decir, velocidad mecánica cero ($\omega_m = 0$) y consecuentemente deslizamiento igual a uno ($S=1$ ya que $\omega_s=\omega_r$).

De este modo es posible definir la transformación de la máquina de inducción de acuerdo al esquema de la Ilustración 5.




Ilustración 5 – Relación de transformación

Tal como se muestra en la ilustración, la frecuencia eléctrica de las variables rotóricas debe corregirse en función del deslizamiento S (cuociente de las velocidades de rotación de los campos magnéticos del rotor y estator).

Es importante destacar que la expresión $S \cdot \omega_s$ representa físicamente la velocidad del campo magnético rotatorio del rotor respecto de sí mismo, por lo tanto se trata de una velocidad relativa. Para obtener la velocidad en términos absolutos debe sumarse la velocidad de giro mecánica del rotor con lo cual la velocidad de la fuerza magneto motriz es $S \cdot \omega_s + \omega_m$ que corresponde a la velocidad sincrónica ω_s .

Desde el punto de vista del circuito equivalente, el hecho que las variables de rotor y estator compartan una misma frecuencia (frecuencia sincrónica) permite que todos los cálculos sean realizados en forma fasorial. Conforme a esto, el circuito equivalente por fase de la máquina de inducción es el que se muestra en la Ilustración 6

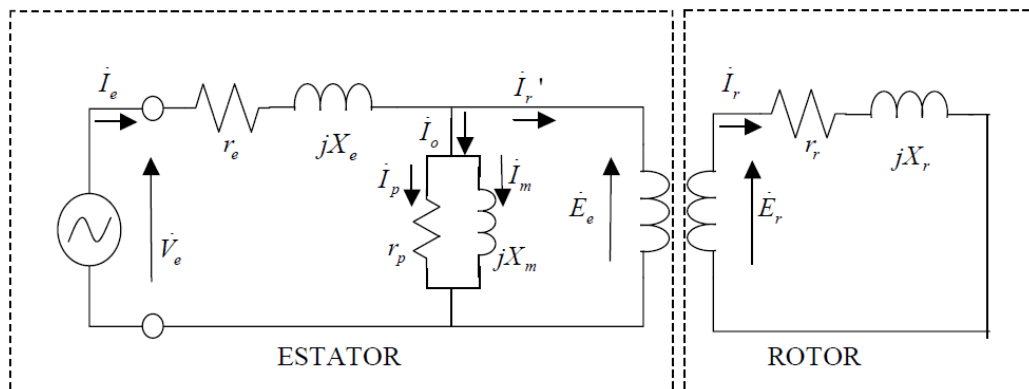


Ilustración 6 – circuito equivalente por fase (general)

La deducción del circuito de la figura se realiza de la siguiente forma:

- Las resistencias r_e y r_r representan las pérdidas en los enrollados de estator y rotor respectivamente.
- Las inductancias x_e y x_r modelan las pérdidas por flujos de fuga en el estator y rotor respectivamente.
- La rama paralela en el estator representa las pérdidas en vacío tales como pérdidas en el hierro en el estator y rotor, pérdidas por roce (que son función de la velocidad) y pérdidas adicionales.

Para poder observar el comportamiento de la máquina de inducción a partir del circuito equivalente es necesario determinar cómo afecta el deslizamiento a la magnitud de los parámetros del rotor, es decir, encontrar una razón de transformación entre las variables del rotor y estator.

Hecho lo anterior, y realizando ciertas aproximaciones se llega al circuito monofásico equivalente por fase aproximado de la Ilustración 7




Ilustración 7 – Circuito equivalente por fase (referido al estator)

Es común que, en el circuito presentado en la Ilustración 7, la resistencia del rotor $\frac{r_r'}{S}$ sea representada como una resistencia fija (independiente del deslizamiento) más una resistencia variable. De este modo se tiene una analogía de un circuito con carga tal como lo muestra la Ilustración 8.

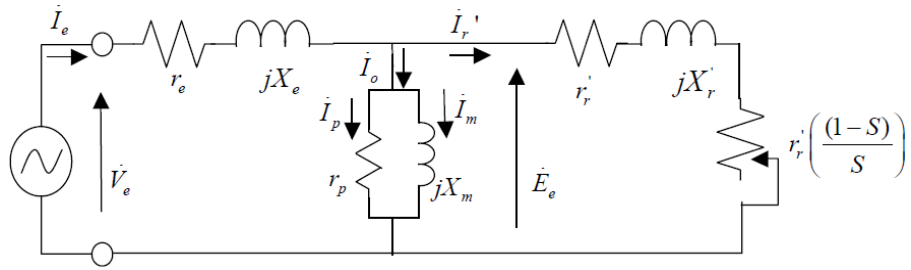


Ilustración 8 – Circuito equivalente por fase (con carga representada)

De este modo, r_r' representa la resistencia equivalente de los enrollados de rotor referidos al estator y la expresión $r_r' \cdot \left(\frac{(1-S)}{S}\right)$ corresponde a la resistencia en el eje, es decir, a la carga mecánica de la máquina.

Analizando el circuito equivalente monofásico del motor de inducción, se tiene que la potencia monofásica transferida al eje corresponde a la potencia transferida al rotor:

$$P_{rotor} = \frac{r_r'}{S} \cdot (I_r')^2$$

Sin embargo parte de esa potencia se pierde en calor:

$$P_{perd} = r_r' \cdot (I_r')^2$$

Por lo tanto la potencia efectiva transferida al eje es:

$$P_{mec} = r_r' \cdot \left(\frac{(1-S)}{S}\right) \cdot (I_r')^2$$

Para el caso trifásico basta multiplicar la potencia monofásica por tres.

$$P_{mec3\phi} = 3 \cdot r_r' \cdot \left(\frac{(1-S)}{S}\right) \cdot (I_r')^2$$

A partir de la ecuación anterior es posible obtener la siguiente expresión para el torque electro mecánico:

$$T_{3\phi} = \frac{P_{mec3\phi}}{w_m} = \frac{3 \cdot r_r' \cdot \left(\frac{1-S}{S}\right) \cdot (I_r')^2}{(1-S) \cdot w_s} = \frac{1}{w_s} \cdot \left(\frac{3 \cdot r_r' \cdot (I_r')^2}{S} \right)$$

El valor de la corriente $I_r' = |I_r'|$ se obtiene al resolver el circuito de la Ilustración 7.

$$I_r' = \frac{V_e}{\left(r_e + \frac{r_r'}{S} \right) + j \cdot (x_e + x_r')}$$

Con lo cual:

$$T_{3\phi} = \frac{3 \cdot r_r'}{S \cdot w_s} \cdot \frac{V_e^2}{\left(r_e + \frac{r_r'}{S} \right) + (x_e + x_r')^2}$$

El torque máximo en función del deslizamiento es:

$$\frac{\partial T_{3\phi}}{\partial S} = 0 \Rightarrow T_{\max} = \frac{3}{2 \cdot w_s} \cdot \frac{V_e^2}{r_e + \sqrt{r_e^2 + (x_e + x_r')^2}}$$




Ilustración 9 – Curva Torque – Velocidad

Los circuitos equivalentes para el motor de inducción y las ecuaciones que describen su funcionamiento permiten establecer la demanda de potencia que ejercerá un motor de estas características a un sistema eléctrico de tracción (Vargas, Romo, & del Valle, 2003).

2.1.2.3. Características de motores utilizados en transporte

2.1.2.3.1. Condiciones de trabajo

Los motores de tracción instalados en los vehículos eléctricos trabajan en condiciones adversas en la mayor parte de su vida útil. Esto se debe principalmente al ambiente en el cual se desempeñan y a los esfuerzos a los cuales son sometidos.

Como una de las soluciones más típicas de instalación es situar los motores en los ejes de las ruedas, éstos quedan expuestos a la posibilidad de sufrir cuantiosos daños por estar a la intemperie.

Cambios en las condiciones atmosféricas como la humedad y la temperatura; aire con alto contenido de limaduras de hierro provenientes de las zapatas de freno, de los patines de retorno de la corriente de tracción, son algunos de los escenarios en los cuales los motores estarán inmersos en su desempeño como máquina de tracción eléctrica.

Por otra parte, y como se mencionó anteriormente, los esfuerzos a los cuales son sometidos los motores eléctricos también se deben considerar dentro de las adversidades por las cuales debe pasar el motor eléctrico de tracción.

Las condiciones de explotación exigen de los motores sobrecargas considerables, por ejemplo:

- Durante el arranque o al subir una pendiente.
- Durante el viaje a mayores velocidades aparecen mayores fuerzas centrífugas en los elementos de los rotores de los motores eléctricos de tracción.
- Cuando el material rodante está alimentado desde un conductor aéreo (catenaria), las interrupciones en el contacto entre el conductor y el sistema de tomacorriente colector del tren (catenaria), dan lugar a cambios violentos de corriente que causan considerables fuerzas dinámicas en los motores. Esto sucede también con tercer riel al abandonar el frotador del motor el tercer riel en alguna zona (zonas de cambio de vías, por ejemplo).

La distancia considerable de las subestaciones de alimentación de tracción ocasiona caídas de voltaje elevadas. En tracción hasta del orden de un 40% de caída de tensión es aceptable.

Dentro de las diversas funciones en el comportamiento de los motores de tracción se encuentran:

- Amplio control de velocidad
- Permitir un gran torque a bajas velocidades
- Soportar sobrecargas instantáneas
- Asegurar la posibilidad de frenado eléctrico en una amplia gama de velocidades

Una ventaja de la tracción eléctrica es la posibilidad de sobrecarga de los motores de tracción. Durante el arranque, para obtener mayor aceleración al subir una pendiente, el motor eléctrico de tracción se puede sobrecargar hasta dos veces su valor nominal. Las locomotoras de combustión diesel no se pueden sobrecargar. Tratando de resolver este problema nació la tracción eléctrica en Berlín en 1870 (Siemens).




Ilustración 10 – Coche de metro

2.1.2.3.2. Conexión de motores en tracción eléctrica

La conexión de motores se realiza para disponer de mayor potencia en la tracción de un tren. Para esta finalidad, los motores se disponen en los bogies en conexión serie. Los bogies son los encargados de permitir al material rodante inscribirse en forma adecuada en las curvas.




Ilustración 11 – Coche ferroviario en curva




Ilustración 12 – Bogue de un coche motor de metro de rodado sobre neumáticos, trenes con motores de corriente continua conexión serie

2.1.3. Sistemas de tracción

2.1.3.1. Aspectos sobre alimentación eléctrica de sistemas ferroviarios de transporte urbano.




Ilustración 13– Circuito de tracción

Consideremos la Ilustración 13. Una fuente de energía (Subestación), una línea de contacto (catenaria), una locomotora que utiliza la corriente del circuito para alimentar a sus motores y poder realizar la tracción eléctrica y un conductor de retorno que cierra el circuito (los rieles).

En cuanto a la fuente de energía, esta será una subestación eléctrica, la cual efectuará una transformación, o sea, una conversión de corriente. Esta subestación que alimenta la línea de contacto estará a su vez alimentada por una línea de alta tensión, a partir de centrales generadoras o de subestaciones transformadoras.

Como el dominio alimentado por una subestación es limitado, aunque se extienda 50 o 60 km. en el caso de una alimentación en alta tensión (25 kV), es que se tendrán varias subestaciones escalonadas a lo largo de la línea.

Un sistema de tracción eléctrica puede ser visto desde dos puntos de vista diferentes, por un lado el del transporte de la energía hasta el pantógrafo de la locomotora, que no es otra cosa que el punto de conexión entre el circuito y el motor eléctrico del tren, y por otro, el de la utilización de esta energía en el vehículo motor.

Para el caso de Metro, se tiene un esquema de alimentación general que consiste en la transformación de la energía eléctrica desde los 110 kV hasta los 20 kV, para luego rectificar esta tensión mediante grupos de rectificación dodecafásicos los cuales llegan a ofrecer tensiones de 750 Volts continuos en sus bornes.

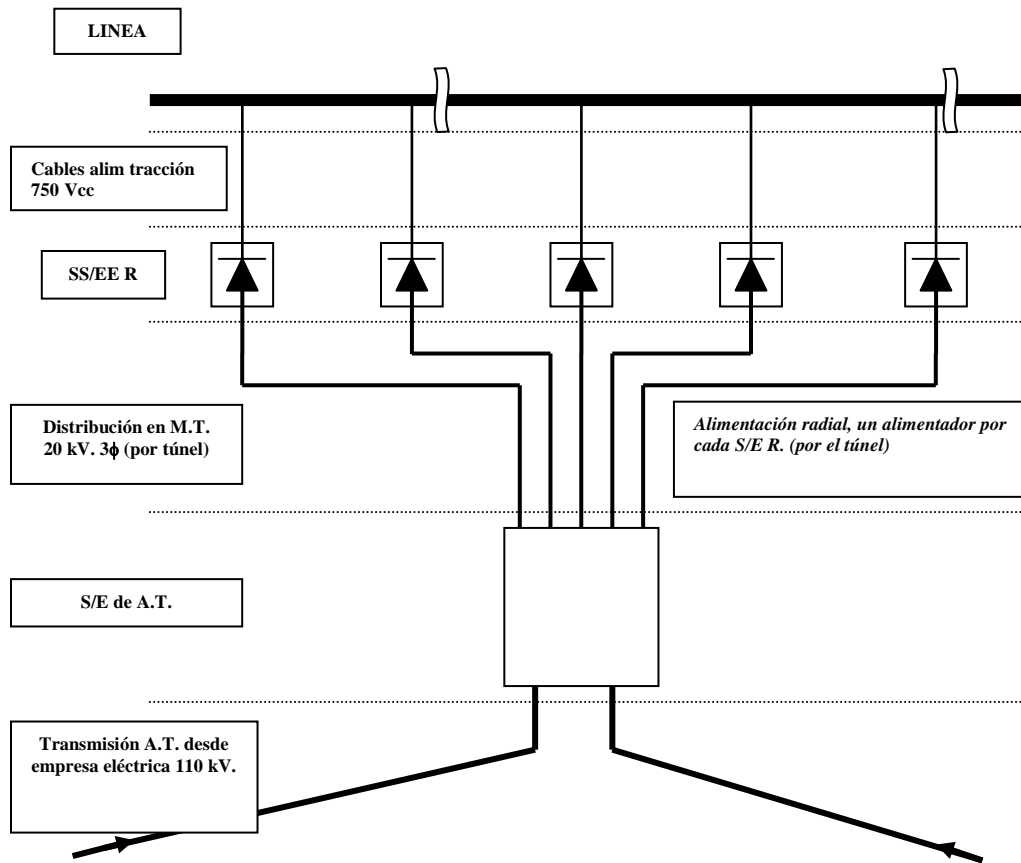


Ilustración 14 – Esquema de alimentación subestaciones de rectificación tracción sistema Metro

2.1.3.2. Ubicación de subestaciones de tracción en una línea de metro (Método clásico)

Con la finalidad de ubicar las subestaciones de tracción en una línea de Metro, se utilizará un modelo matemático de la línea el cual permitirá diseñar el sistema persiguiendo una función determinada y satisfaciendo las restricciones del problema. Este modelo permitirá entre otras cosas, entender los requerimientos de potencia y energía en un circuito de tracción.

Para el modelo matemático de la línea, y el final diseño de la ubicación de las subestaciones de tracción, se considerará lo siguiente:

1. Potencia de tracción requerida a la hora de demanda máxima (hora de punta) para una vía: P_t
2. Se supone P_t uniformemente distribuida a lo largo de la línea.
3. Modelo.
4. Potencia de cada S/E R, normas de tracción, pérdidas Joule.
5. Costos de inversión, de mantenimiento, de operación.
6. Función de costos.

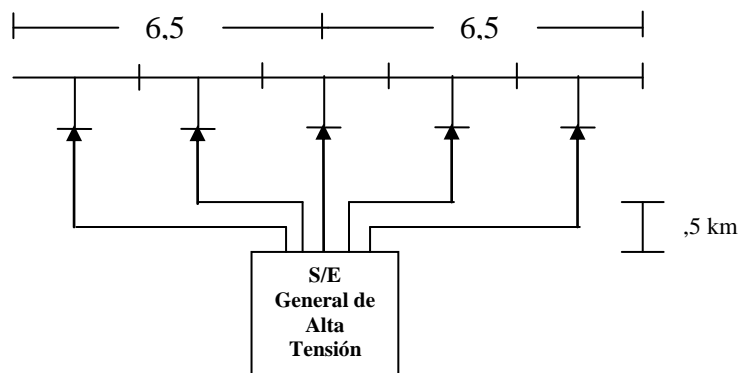


Ilustración 15– Ejemplo de ubicación de Subestaciones de rectificación en una línea de tracción.

En el ejemplo se puede visualizar las subestaciones de rectificación distribuidas a lo largo de la línea. La corriente alterna proviene de la Subestación general de alta tensión, y es rectificadas mediante las subestaciones de tracción.

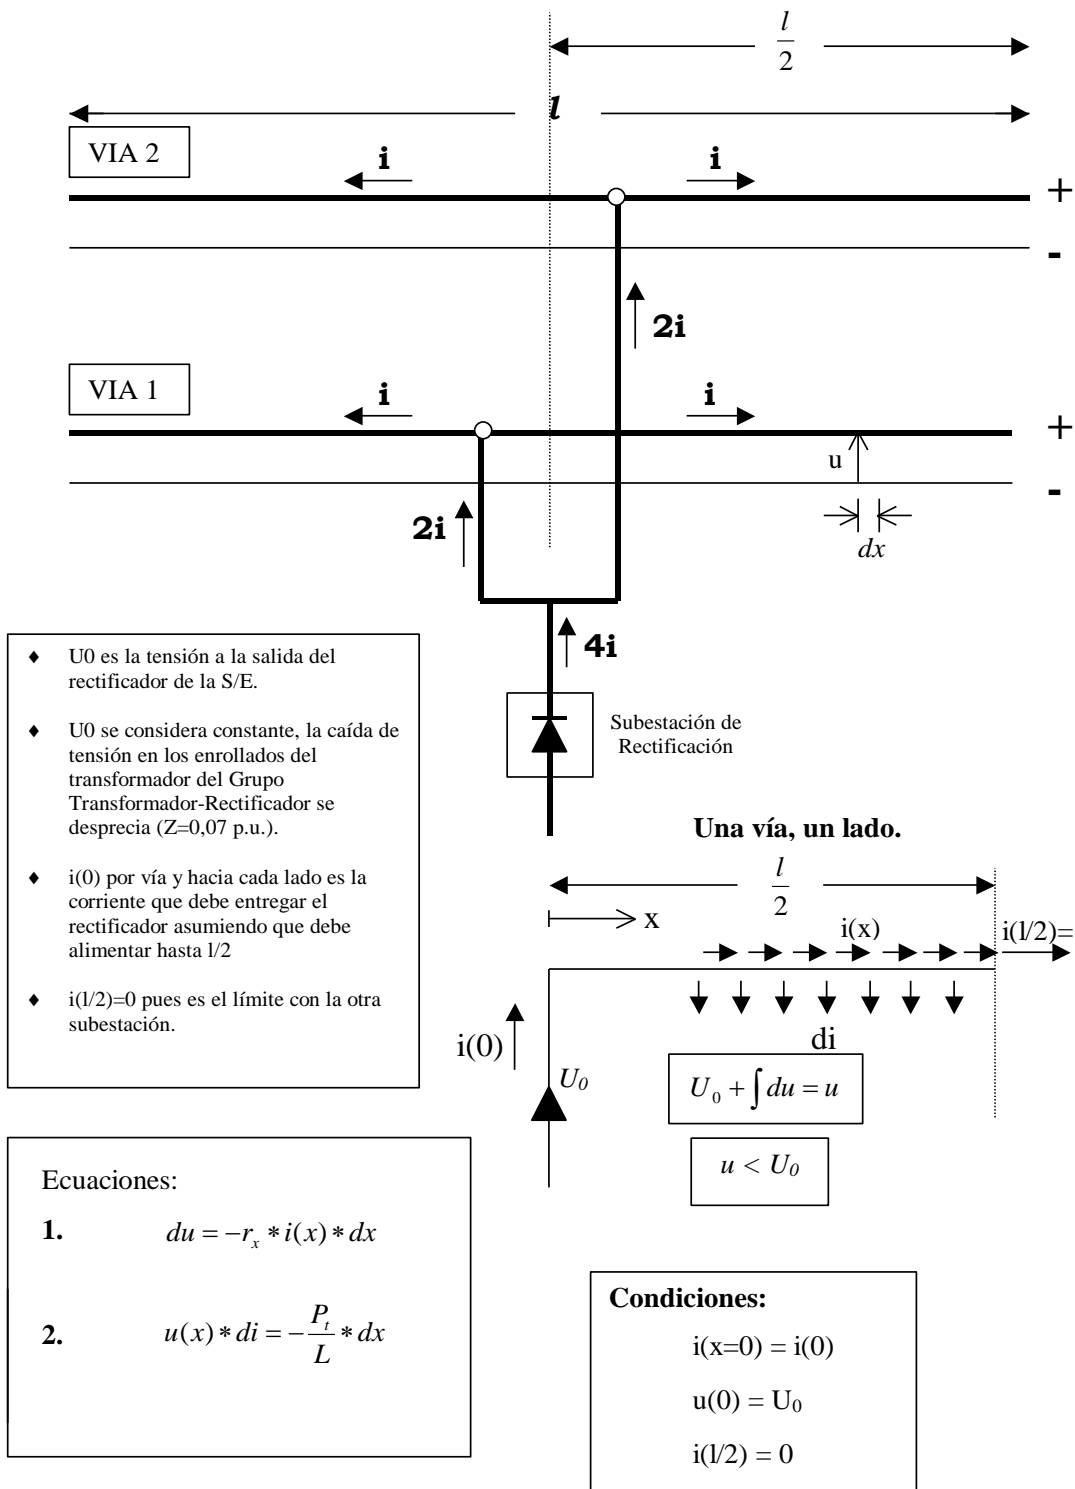


Ilustración 16 – Modelo matemático clásico de una línea de Metro.




Ilustración 17– Inyecciones de corriente continua en la línea.

Caso más restrictivo: Falla la S/E 1 y debe apoyar la S/E 2, la cual debe alimentar tramos de línea de longitudes $l/2$ y $3l/2$

Elemento de línea alimentado por cada S/E:	$l = L / N$
Longitud de la línea:	L
Tramo que alimenta una S / E en condiciones normales:	l
Cantidad de SS/EE R:	N




Ilustración 18– Distribución de corrientes de inyección de cada subestación de rectificación

$$P_a = \frac{1}{2} P_0(l_{01}) + \frac{1}{2} P_0(l_{02})$$

La S/E 2, en caso de falla de la S/E 1 debe suministrar la potencia de auxilio (P_a). De acuerdo a las normas de equipos eléctricos de tracción, la potencia nominal es

$$P_n = \frac{P_a}{1,5}$$

Finalmente, la ecuación que rige el sistema dinámico es:

$$\frac{U_0 T}{3600 \cdot C \cdot N_c \cdot 10^3} \cdot e^{-\frac{r_x T}{7200 C \cdot N_c \cdot 10^3} i(0)^2} \int_0^{i(0)} e^{\frac{r_x T}{7200 C \cdot N_c \cdot 10^3} i(x)^2} di = \frac{l}{2}$$

Se deben considerar las siguientes caídas de tensión que se tienen para llegar desde la subestación rectificadora hasta el circuito de tracción.

1. Caída de tensión interna de la S/E R.
2. Caída de tensión en la línea.
3. Caída de tensión eventual producida por la partida de un tren.
4. Caída de tensión en los cables de alimentación tracción desde la S/E R hasta la línea
5. El cálculo se realiza considerando una S/E funcionando en régimen de socorro, es decir la S/E adyacente fuera de servicio, para el caso más restrictivo.

El voltaje nominal que se tiene en bornes del rectificador es:

$$V_v = \sqrt{2} \cdot V_{ff} \cdot \frac{\frac{\pi}{p}}{\frac{\pi}{p}} = \frac{3\sqrt{2}}{\pi} V_{ff} = \frac{3\sqrt{2}}{\pi} 600 = 810[V]$$

Considerando la caída interna en el grupo rectificador:

$$V_{cc} = V_v - R_i \cdot I_{cc} = V_v - \Delta U_{int}$$

$$V_{cc} = 810 - 0,01233 \cdot 2 \cdot (I_{01} + I_{02})$$




Ilustración 19– Caída de tensión en el grupo rectificador y en la línea

En la Línea se tendrá una caída de voltaje debido al efecto Joule.

$$\Delta U_L = r_x \cdot \frac{l_{mayor}}{2} \cdot I_{02}$$

En la partida del tren existirá una baja en el voltaje dada por:

$$\Delta U_p = r_x \cdot I_p \cdot l_{02}$$

Asimismo el efecto Joule en los cables de tracción es de la forma

$$\Delta U_c = \frac{2 \cdot R_c \cdot L_G \cdot (I_{01} + I_{02}) \cdot 2}{N_c}$$

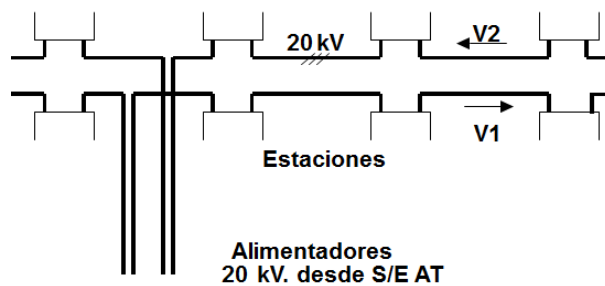


Ilustración 20– Distribución en 20 kV

La distribución en 20 kV. para alimentar las subestaciones de alumbrado y fuerza de las estaciones se realiza mediante cables trifásicos, tripolares o monopolares, que salen desde los interruptores de salida de 20 kV. en la Subestación de Alta Tensión y recorren la línea por cada vía alimentando en bucle (en paralelo).

Desde aproximadamente el centro de la línea llega para cada vía un alimentador, por lo cual en este esquema existen cuatro alimentadores. Cada alimentador llega a una celda de llegada provista de un interruptor, alimenta la celda de protección (fusible e interruptor) del transformador de la subestación y continúa para alimenta (en paralelo) una celda provista de un interruptor para seguir el alimentador a la estación siguiente.

En las estaciones terminales existe la posibilidad de cerrar el bucle de 20 kV para alimentar desde el otro alimentador en caso de una falla de cable en una zona intermedia, aislando la zona fallada. En condiciones normales no está permitido cerrar estos bucles pues significaría conectar dos alimentadores.

2.1.3.3. Ubicación de subestaciones de tracción en una línea de metro (Por simulación de la marcha de un tren)

2.1.3.3.1. Ecuación dinámica

Para efectuar la simulación de la marcha de un tren se recurre a la ecuación de la dinámica:

$$F_m - F_r = M \cdot a$$

F_m : Fuerza motriz del tren (Newton)

F_r : Fuerza de resistencia al rodado (Newton)

M : Masa del tren corregida por efectos inercia (kg.)

$$M = m \cdot 1,124 \quad (1,124: \text{Factor dado por el fabricante})$$

m : Masa del tren (kg.)

a : aceleración (m/seg²)

Esta ecuación debe aplicarse para las fases de:

- Tracción
- Marcha inercial
- Frenado

2.1.3.3.2. Sistema discreto

Para resolver la ecuación se debe calcular en cada intervalo de simulación, la aceleración, la velocidad y la distancia acumulada. Para ello se recurre a discretizar el sistema.

Las ecuaciones son las ecuaciones de la cinemática aplicadas a cada intervalo de simulación:

$$a_i = (F_m - F_r)/M$$

$$v_i = v_{i-1} + a_i \cdot \Delta t$$

$$s_i = s_{i-1} + v_{i-1} \cdot \Delta t + \frac{1}{2} \cdot a_i \cdot \Delta t^2$$

a_i : aceleración en el intervalo i (m/seg²)

v_i : velocidad en el intervalo i (m/seg)

Δt : intervalo de simulación (seg)

s_i : distancia acumulada en el intervalo i (m)

2.1.3.3. Fuerza motriz (Trenes con motores de corriente continua)

2.1.3.3.1. Fuerza motriz en función de la corriente

Por especificaciones de fábrica, el esfuerzo en llantas **por motor** en función de la corriente está dado por curvas, las cuales linealizadas quedan representadas por las siguientes ecuaciones:

$$F_m = 53 \cdot I - 5902 \quad 0 \leq t < 9$$

$$F_m = 52 \cdot I - 8490 \quad 0 \leq t < 11$$

$$F_m = 43 \cdot I - 7867 \quad 11 \leq t < 13$$

$$F_m = 37 \cdot I - 7610 \quad 13 \leq t$$

$$F_m \text{ (Newton); } I \text{ (Amperes); } t \text{ (seg)}$$

2.1.3.3.2. Corriente de un motor en función del tiempo

De la inscripción de corriente en función del tiempo de un coche motriz (4 motores conectados todos en serie al comienzo y después en serie – paralelo), se obtiene la curva de corriente de un motor en función del tiempo, la cual linealizada queda representada por las siguientes ecuaciones:

$$I(t) = 133 \cdot I + 180 \quad 0 \leq t < 3$$

$$I(t) = 580 \quad 3 \leq t < 5$$

$$I(t) = 510 \quad 5 \leq t < 9$$

$$I(t) = -40 \cdot t + 890 \quad 9 \leq t < 11$$

$$I(t) = -45 \cdot t + 1065 \quad 11 \leq t < 13$$

$$I(t) = -13 \cdot t + 767 \quad 13 \leq t$$

2.1.3.3.3. Fuerza motriz en función del tiempo

Efectuando los reemplazos, las ecuaciones que rigen la fuerza motriz en función del tiempo **para un motor**, son para un material rodante, formado por trenes de 5 coches (3 motrices con 4 motores c/u, 2 por boguie), total 12 motores:

$$F_m(t) = 7049 \cdot t + 3638 \quad 0 \leq t < 3 \quad F_m \text{ (Newton)}$$

$$F_m(t) = 24838 \quad 3 \leq t < 5$$

$$F_m(t) = 21128 \quad 5 \leq t < 9$$

$$F_m(t) = -2080 \cdot t + 37790 \quad 9 \leq t < 11$$

$$F_m(t) = -1935 \cdot t + 37928 \quad 11 \leq t < 13$$

$$F_m(t) = -481 \cdot t + 20767 \quad 13 \leq t$$

Esto es para un motor.

Para 12 motores multiplicar por 12.

2.1.3.3.4. Fuerza de resistencia al rodado

Para el caso de un tren de metro de cinco coches c/u, según especificaciones de fábrica, el esfuerzo de resistencia al avance efectuando equivalencias de gradientes y curvas, queda representado por:

$$F_r = \left(11,6 + g_{equiv} + 500 \cdot \frac{T_r}{R_{equiv}} \right) \cdot P + 25,92 \cdot v^2$$

F_r (Newton) : Fuerza de resistencia al rodado

P (Kilo-Newton) : Peso total del tren

g_{equiv} (por mil) : Gradiente equivalente

T_r (metros) : Trocha

R_{equiv} (metros) : Radio equivalente

(m/seg.) : Velocidad

2.1.3.3.5. Ejemplo de simulación

Cantidad de motores de un tren de 5 coches	:	12
Masa del tren	:	184 Ton.
Gradiente equivalente	:	4,5 por mil
Curvas	:	No hay
Desaceleración de frenado	:	-1,2 m/seg ²

Velocidad máxima en esta interestación : 70 km/h

Velocidad comienzo de frenado : 45 km/h

Distancia interestación considerada para

este problema : 760 metros

Si esta interestación se repite un cierto número de veces en un trazado, por ejemplo 10 estaciones, se puede determinar con el método de simulación la cantidad de subestaciones de rectificación, su potencia y la corriente máxima entregada por cada una de ellas, considerando un intervalo de explotación de diseño, por ejemplo de 90 seg.

La línea queda discretizada en segmentos de largo no uniforme, correspondientes c/u de ellos a una celda de simulación separadas en el intervalo de simulación de valor constante, en este caso 1 segundo.

SIMULACION DE LA MARCHA DE UN TREN

					Desacelerac.					
Requiv.	Tr (m.)	Masa tren Ton.	Nº motores	g equiv. por mil	frenado (m/seg2)					
infinito	1,435	184	12	4,5	-1,2					

3,6

t seg.	I Amperes	Fm 1 motor Newton	Fm 12 motor Newton	Fr Newton	Acelerac m/seg2	Veloc m/seg.	Veloc km/h	Distancia s (m.)	Energía cons.(Wh)
0	180	3.638	43.656		0,00	0,00	0,00	0,00	0,0
1	313	10.687	128.244	29.624,00	0,48	0,48	1,73	0,24	17,099
2	446	17.736	212.832	29.629,97	0,89	1,37	4,93	1,17	81,0
3	580	24.785	297.420	29.672,65	1,29	2,66	9,58	3,19	219,8
4	580	24.838	298.056	29.807,40	1,30	3,96	14,26	6,50	327,9
5	510	21.128	253.536	30.030,47	1,08	5,04	18,14	11,00	355,0
6	510	21.128	253.536	30.282,41	1,08	6,12	22,03	16,58	431,0
7	510	21.128	253.536	30.594,82	1,08	7,20	25,92	23,24	507,1
8	510	21.128	253.536	30.967,69	1,08	8,28	29,81	30,98	583,1
9	530	19.070	228.840	31.401,03	0,95	9,23	33,23	39,74	586,7
10	490	16.990	203.880	31.832,20	0,83	10,06	36,22	49,39	569,7
11	570	16.643	199.716	32.247,20	0,81	10,87	39,13	59,86	603,0
12	525	14.708	176.496	32.686,63	0,70	11,57	41,65	71,08	567,2
13	480	14.514	174.168	33.093,78	0,68	12,25	44,10	82,99	592,7
14	585	14.033	168.396	33.513,62	0,65	12,90	46,44	95,57	603,4
15	572	13.552	162.624	33.937,35	0,62	13,52	48,67	108,78	610,7
16	559	13.071	156.852	34.361,93	0,59	14,11	50,80	122,60	614,8
17	546	12.590	151.080	34.784,47	0,56	14,67	52,81	136,99	615,7
18	533	12.109	145.308	35.202,21	0,53	15,20	54,72	151,93	613,5
19	520	11.628	139.536	35.612,56	0,50	15,70	56,52	167,38	608,5
20	507	11.147	133.764	36.013,02	0,47	16,17	58,21	183,32	600,8
21	494	10.666	127.992	36.401,27	0,44	16,61	59,80	199,71	590,5
22	481	10.185	122.220	36.775,12	0,41	17,02	61,27	216,53	577,8
23	468	9.704	116.448	37.132,52	0,38	17,40	62,64	233,74	562,8
24	455	9.223	110.676	37.471,54	0,35	17,75	63,90	251,32	545,7
25	442	8.742	104.904	37.790,42	0,32	18,07	65,05	269,23	526,6
26	429	8.261	99.132	38.087,53	0,30	18,37	66,13	287,45	505,8
27	0	0	0	38.370,88	-0,19	18,18	65,45	305,73	0,0
28	0	0	0	38.190,88	-0,18	18,00	64,80	323,82	0,0
29	0	0	0	38.022,08	-0,18	17,82	64,15	341,73	0,0
30	0	0	0	37.854,96	-0,18	17,64	63,50	359,46	0,0
31	0	0	0	37.689,52	-0,18	17,46	62,86	377,01	0,0
32	0	0	0	37.525,75	-0,18	17,28	62,21	394,38	0,0
33	0	0	0	37.363,67	-0,18	17,10	61,56	411,57	0,0

Ilustración 21– Simulación de la marcha de un tren (parte 1)

SIMULACION DE LA MARCHA DE UN TREN

Requiv.	Tr (m)	Masa tren Ton	Nº motores	g equiv. por mil	Desacelerac. frenado (m/seg ²)					
infinito	1,435	184	12	4,5	-1,2	3,6				
t seg.	I Amperes	Fm 1 motor Newton	Fm 12 motor Newton	Fr Newton	Acelerac m/seg ²	Veloc m/seg.	Veloc km/h	Distancia s (m.)	Energía cons.(Wh)	
34	0	0	0	37.203,27	-0,18	16,92	60,91	428,58	0,0	
35	0	0	0	37.044,54	-0,18	16,74	60,26	445,41	0,0	
36	0	0	0	36.887,50	-0,18	16,56	59,62	462,06	0,0	
37	0	0	0	36.732,13	-0,18	16,38	58,97	478,53	0,0	
38	0	0	0	36.578,45	-0,18	16,20	58,32	494,82	0,0	
39	0	0	0	36.426,44	-0,18	16,02	57,67	510,93	0,0	
40	0	0	0	36.276,12	-0,18	15,84	57,02	526,86	0,0	
41	0	0	0	36.127,47	-0,17	15,67	56,41	542,62	0,0	
42	0	0	0	35.988,63	-0,17	15,50	55,80	558,21	0,0	
43	0	0	0	35.851,28	-0,17	15,33	55,19	573,63	0,0	
44	0	0	0	35.715,43	-0,17	15,16	54,58	588,88	0,0	
45	0	0	0	35.581,08	-0,17	14,99	53,96	603,96	0,0	
46	0	0	0	35.448,23	-0,17	14,82	53,35	618,87	0,0	
47	0	0	0	35.316,87	-0,17	14,65	52,74	633,61	0,0	
48	0	0	0	35.187,02	-0,17	14,48	52,13	648,18	0,0	
49	0	0	0	35.058,66	-0,17	14,31	51,52	662,58	0,0	
50	0	0	0	34.931,80	-0,17	14,14	50,90	676,81	0,0	
51	0	0	0	34.806,43	-1,20	12,94	46,58	690,35	0,0	
52	0	0	0	33.964,14	-1,20	11,74	42,26	702,69	0,0	
53	0	0	0	33.196,49	-1,20	10,54	37,94	713,83	0,0	
54	0	0	0	32.503,49	-1,20	9,34	33,62	723,77	0,0	
55	0	0	0	31.885,15	-1,20	8,14	29,30	732,51	0,0	
56	0	0	0	31.341,45	-1,20	6,94	24,98	740,05	0,0	
57	0	0	0	30.872,40	-1,20	5,74	20,66	746,39	0,0	
58	0	0	0	30.478,00	-1,20	4,54	16,34	751,53	0,0	
59	0	0	0	30.158,25	-1,20	3,34	12,02	755,47	0,0	
60	0	0	0	29.913,15	-1,20	2,14	7,70	758,21	0,0	
61	0	0	0	29.742,70	-1,20	0,94	3,38	759,75	0,0	
62	0	0	0	29.646,90	-1,20	-0,26	-0,94	760,09	0,0	
								Wh totales	13.018,0	
								kWh totales	13,0	
								kWh/tren-km	17,1	
								kWh/coche-km	3,43	

Ilustración 22– Trabajo efectuado por una fuerza para provocar un movimiento (parte 2)

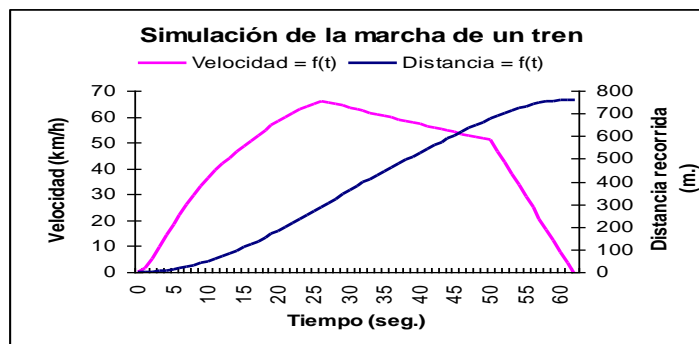


Ilustración 23– Gráfico de la simulación

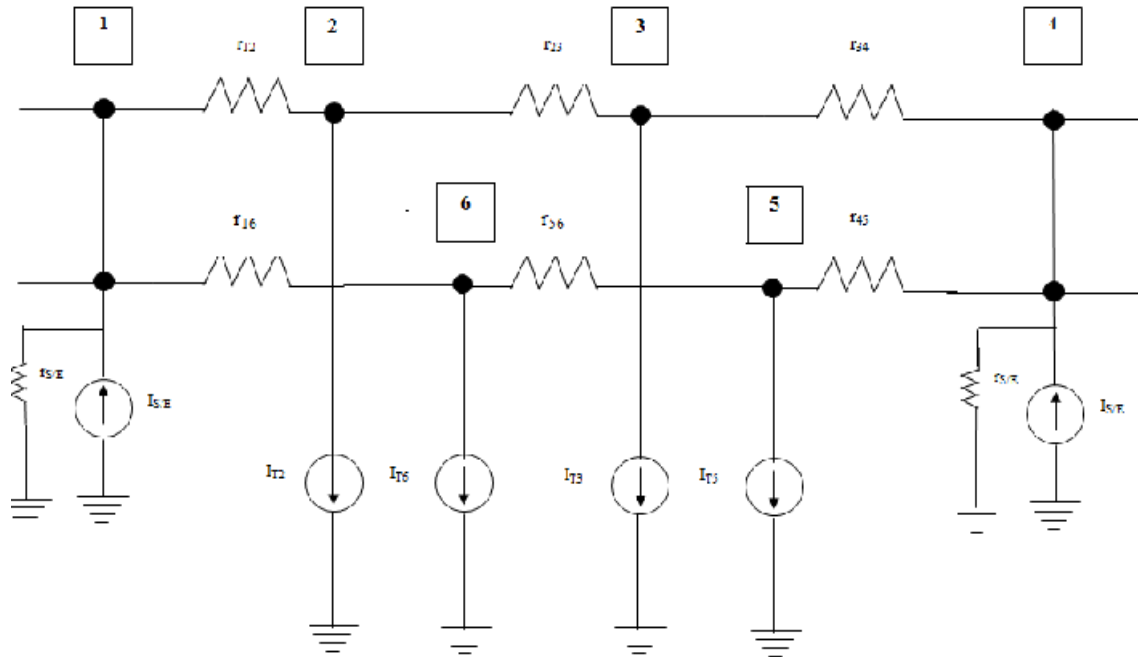


Ilustración 24– Modelo circuital de la línea, trenes y subestaciones de rectificación

$$\begin{bmatrix}
 \frac{1}{r_{12}} + \frac{1}{r_{16}} & -\frac{1}{r_{12}} & 0 & 0 & 0 & -\frac{1}{r_{16}} \\
 -\frac{1}{r_{12}} & \frac{1}{r_{12}} + \frac{1}{r_{23}} & -\frac{1}{r_{23}} & 0 & 0 & 0 \\
 0 & -\frac{1}{r_{23}} & \frac{1}{r_{23}} + \frac{1}{r_{34}} & -\frac{1}{r_{34}} & 0 & 0 \\
 0 & 0 & -\frac{1}{r_{34}} & \frac{1}{r_{34}} + \frac{1}{r_{45}} & -\frac{1}{r_{45}} & 0 \\
 0 & 0 & 0 & -\frac{1}{r_{45}} & \frac{1}{r_{45}} + \frac{1}{r_{56}} & -\frac{1}{r_{56}} \\
 0 & 0 & 0 & 0 & -\frac{1}{r_{56}} & \frac{1}{r_{16}} + \frac{1}{r_{56}}
 \end{bmatrix}
 \begin{bmatrix}
 v_1 \\
 v_2 \\
 v_3 \\
 v_4 \\
 v_5 \\
 v_6
 \end{bmatrix}
 =
 \begin{bmatrix}
 -I_{S/E} \\
 I_{T2} \\
 I_{T3} \\
 -I_{S/E} \\
 I_{T5} \\
 I_{T6}
 \end{bmatrix}$$

Ilustración 25– Ecuación matricial del modelo circuital de la línea.

2.2.PREDICCIÓN DE SERIES DE TIEMPO

La predicción de eventos futuros utilizando información del presente y del pasado ha sido una de las principales inquietudes del hombre, a lo largo de su historia, y más aún en las últimas décadas.

Hoy en día, los pronósticos se realizan con la finalidad de orientar las decisiones en distintas áreas, como los mercados, el clima, el transporte, entre otros. Para pronosticar una variable se debe construir un modelo matemático que permita describir la dinámica temporal, y sus parámetros se deben estimar utilizando datos históricos, es decir, se debe lograr una caracterización estadística de los enlaces entre el presente y el pasado.

Existirán entonces distintas metodologías que utilicen las premisas mencionadas anteriormente y que tratarán de realizar las mejores predicciones de series de tiempo de una determinada variable. Cada una de estas metodologías tendrá características propias, que le permitirán tener resultados favorables en la predicción de ciertos casos de la realidad.

2.2.1.Modelos de predicción

2.2.1.1. Modelado clásico de series temporales

El primer paso obligatorio para analizar una serie temporal es presentar un gráfico de la evolución de la variable a lo largo del tiempo, como puede ser el de la figura:




Ilustración 26 – Representación de una serie temporal

El siguiente paso consistirá en determinar si la secuencia de valores es completamente aleatoria o si, por el contrario, se puede encontrar algún patrón a lo largo del tiempo, pues sólo en este caso podremos seguir con el análisis.

La metodología tradicional para el estudio de series temporales es bastante sencilla de comprender, y fundamentalmente se basa en descomponer las series en varias partes: tendencia, variación estacional o periódica, y otras fluctuaciones irregulares.

- Tendencia. Es la dirección general de la variable en el periodo de observación, es decir el cambio a largo plazo de la media de la serie.
- Estacionalidad. Corresponde a fluctuaciones periódicas de la variable, en periodos relativamente cortos de tiempo.
- Otras fluctuaciones irregulares. Después de extraer de la serie la tendencia y variaciones cíclicas, nos quedará una serie de valores residuales, que pueden ser o no totalmente aleatorios. Volvemos a estar como en el punto de partida, pues ahora también nos interesa determinar si esa secuencia temporal de valores residuales puede o no ser considerada como aleatoria pura.

En la Ilustración 27 vemos un ejemplo de una serie temporal en la que se aprecia la existencia de las distintas componentes comentadas




Ilustración 27 – Serie temporal con tendencia

2.2.1.1.1. Análisis de la tendencia

Una primera idea sobre la presencia de tendencia en la serie la obtendremos en su representación gráfica. Pero no siempre estará tan clara como en la Ilustración 27. Por ejemplo, en la siguiente imagen sigue habiendo tendencia pero ya no es tan marcada.




Ilustración 28 – Otra serie temporal con tendencia (menos pronunciada)

Los medios más utilizados para detectar y eliminar la tendencia de una serie se basan en la aplicación de filtros a los datos. Un filtro no es más que una función matemática que aplicada a los valores de la serie produce una nueva serie con unas características determinadas. Entre esos filtros encontramos las medias móviles.

Una media móvil se calcula, para cada punto, como un promedio del mismo número de valores a cada lado de ese punto. Así una media móvil de tres puntos se calcula como:

$$m(x_t) = \frac{x_{t-1} + x_t + x_{t+1}}{3}$$

Mientras que una media móvil de cuatro puntos viene dada por

$$m(x_t) = \frac{(x_{t-2}/2) + x_{t-1} + x_t + x_{t+1} + (x_{t+2}/2)}{4}$$

Cuando la cantidad de puntos de la media móvil es par, se toma la mitad de los valores extremos.

Existen otros procedimientos para extraer la tendencia, como ajuste de polinomios, alisado mediante funciones exponenciales, etc. Una clase de filtro, que es particularmente útil para eliminar la tendencia, se basa en aplicar diferencias a la serie hasta convertirla en estacionaria. Una diferencia de primer orden se obtiene restando dos valores contiguos:

$$\nabla x_{t+1} = x_{t+1} - x_t$$

Si volvemos a diferenciar esa serie, restando los nuevos valores consecutivos obtenemos una nueva serie más suavizada.

$$\nabla^2 x_{t+2} = \nabla x_{t+2} - \nabla x_{t+1}$$

Una vez que se aplica un proceso clásico de descomposición mediante un procedimiento de medias móviles a los datos de la figura 2, se obtiene las siguientes series:




Ilustración 29 – Descomposición de una serie temporal en sus componentes

Para analizar la estacionalidad de una serie introduciremos un concepto de gran interés en el análisis de series temporales: la función de auto-correlación.

La función de auto-correlación mide la correlación entre los valores de la serie distanciados un lapso de tiempo k .

Recordemos la fórmula del coeficiente de correlación simple, dados N pares de observaciones y , x :

$$r = \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum (y_i - \bar{y})^2 \sum (x_i - \bar{x})^2}}$$

De igual forma, dada una secuencia temporal de N observaciones $x_1 \dots x_N$, podemos formar $N-1$ parejas de observaciones contiguas (x_1, x_2) , (x_2, x_3) , ... (x_{N-1}, x_N) y calcular el coeficiente de correlación de estas parejas. A este coeficiente lo denominaremos coeficiente de auto-correlación de orden 1 y lo denotamos como r_1 . Análogamente se pueden formar parejas con puntos separados por una distancia 2, es decir (x_1, x_3) , (x_2, x_4) , etc. y calcular el nuevo coeficiente de auto-correlación de orden 2. De forma general, si preparamos parejas con puntos separados una distancia k , calcularemos el coeficiente de auto-correlación de orden k .

Al igual que para el coeficiente de correlación lineal simple, se puede calcular un error estándar y por tanto un intervalo de confianza para el coeficiente de auto-correlación.

La función de auto-correlación es el conjunto de coeficientes de auto-correlación r_k desde 1 hasta un máximo que no puede exceder la mitad de los valores observados, y es de gran importancia para estudiar la estacionalidad de la serie, ya que si ésta existe, los valores separados entre sí por intervalos iguales al periodo estacional deben estar correlacionados de alguna forma. Es decir que el coeficiente de auto-correlación para un retardo igual al periodo estacional debe ser significativamente diferente de 0.

Relacionada con la función de auto-correlación nos encontramos con la función de auto-correlación parcial. En el coeficiente de auto-correlación parcial de orden k , se calcula la correlación entre parejas de valores separados esa distancia pero eliminando el efecto debido a la correlación producida por retardos anteriores a k .

En la Ilustración 30 vemos una gráfica típica de la función de auto-correlación parcial, en la que se marcan los intervalos de confianza para ayudar a detectar los valores significativos y cuya posición en el eje X nos indicará la probable presencia de un factor de estacionalidad para ese valor de retardo (Seh_lelha_org).




Ilustración 30 – Función de auto-correlación parcial

2.2.1.2. Modelos Autorregresivos (AR)

Este modelo intenta predecir una secuencia de datos en base a una combinación lineal de datos pasados:

$$x_N = \sum_{i=1}^p \rho_i \cdot x_{N-i}$$

La cantidad de datos pasados que se emplean en la predicción indica el orden del modelo utilizado. Los coeficientes ρ_i de la ecuación, se calculan de modo que se minimice el error en la predicción.

$$\min_{a_i} \sum_N (X_N - x_N)^2$$

Donde X_N es el valor real y x_N es la estimación. Los coeficientes ρ_i se pueden obtener de las ecuaciones de Yule-Walker:

$$\begin{bmatrix} \gamma_1 \\ \gamma_2 \\ \gamma_3 \\ \vdots \end{bmatrix} = \begin{bmatrix} \gamma_0 & \gamma_{-1} & \gamma_{-2} & \dots \\ \gamma_1 & \gamma_0 & \gamma_{-1} & \dots \\ \gamma_2 & \gamma_1 & \gamma_0 & \dots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} \begin{bmatrix} \varphi_1 \\ \varphi_2 \\ \varphi_3 \\ \vdots \end{bmatrix}$$

Donde γ_k es la auto-correlación de la información conocida (Estévez, 2011).

2.2.1.3. Modelos ARIMA

A comienzo de los años 70, G.E.P. Box, profesor de Estadística de la Universidad de Wisconsin, y G.M. Jenkins, profesor de Ingeniería de Sistemas de la Universidad de Lancaster, introdujeron una pequeña revolución en el enfoque del análisis de series temporales, en sus trabajos sobre el comportamiento de la contaminación en la bahía de San Francisco, con el propósito de establecer mejores mecanismos de pronóstico y control. El libro (1976) en el que describen la metodología, se convirtió rápidamente en un clásico, y sus procedimientos se utilizan ampliamente desde entonces en diferentes ramas de la ciencia, conociéndose como modelos ARIMA y también como modelos Box-Jenkins.

Para este tipo de modelos, el primer paso consiste en convertir nuestra serie de observaciones en una serie estacionaria, que es aquella en la que ni la media, ni la varianza, ni las auto-correlaciones dependen del tiempo. Una vez "estabilizada" la serie mediante las transformaciones adecuadas, se procede a estudiar la presencia de regularidades en la serie, para identificar un posible modelo matemático. Para ello se calculan la función de auto-correlación simple y parcial, y se compara su forma con un catálogo de patrones gráficos, que son típicos de los diferentes modelos propuestos, seleccionando el modelo que más se adecue a la forma de las funciones de auto-correlación que hemos obtenido con nuestros datos.

Una vez elegida la forma del modelo, se estiman los coeficientes del mismo, y finalmente se procede a efectuar un análisis de los residuos (diferencia entre el valor realmente observado y el valor previsto por el modelo), con el fin de comprobar si el ajuste del modelo a nuestros datos es adecuado. Si no lo fuera repetimos el proceso buscando otros modelos.

Una vez determinado un modelo suficientemente válido, sobre la serie estacionaria, procedemos a deshacer la transformación inicialmente efectuada para estabilizar la serie, y ahora comprobamos si los pronósticos del modelo son adecuados con nuestros datos, volviendo a comenzar la búsqueda de otro modelo si no fuera el caso. Puede por tanto tratarse de un proceso iterativo de mejora del modelo.

En el modelo, cada valor tomado por la variable en un instante dado, está influido por los valores de la variable en momentos anteriores, y se expresa como una relación lineal, función de:

1. Valores recientes de la variable
2. Ruidos en valores recientes de la variable
3. Valores remotos de la variable
4. Ruidos en valores remotos de la variable

El esquema general del modelo es el siguiente:

$$x_t = a_1x_{t-1} + a_2x_{t-2} + \dots + a_px_{t-p} + Z_t + b_1Z_{t-1} + \dots + b_qZ_{t-q}$$

que es la fórmula general de los modelos denominados **ARMA**. Está constituido por una combinación de p términos **AR** (proceso autorregresivo), y q términos **MA** (proceso de medias móviles). La parte **AR** modela la influencia de los valores anteriores de la serie (X_{t-1} hacia atrás), y la parte **MA** modela la influencia del ruido en valores anteriores de la serie (Z_{t-1} hacia atrás), junto con el término Z_t que corresponde al ruido esperado en el mismo momento t en el que se estima el nuevo valor de la variable X .

Una de las ventajas de estos modelos es su gran simplicidad (sumas de términos), frente a los modelos propuestos en la formulación clásica.

La letra **I** que aparece en el nombre del modelo completo **ARIMA**, corresponde al proceso último a realizar, una vez definido el tipo de modelo y estimados los coeficientes de éste, ya que entonces hay que restablecer las características originales de la serie de datos, que fue transformada para inducir estacionalidad. A ese proceso inverso se denomina en general Integración y aporta esa letra que completa el nombre (Estévez, 2011).

2.2.1.4. Redes Neuronales Artificiales (RNA)

2.2.1.4.1. Inteligencia Artificial

La historia de la informática tal y como la conocemos hoy en día es reciente. Hacia finales de los años 30 y durante la década de los 40, los trabajos de gente como Alan Turing o von Neumann asientan las bases de la informática moderna. En un principio se orienta hacia la computación algorítmica, es decir, la resolución de un determinado problema obteniendo un algoritmo que manipula los datos relativos al problema. El binomio hardware + software se muestra como una potente herramienta para la resolución de problemas que el ser humano no podría resolver o que tardaría mucho tiempo en hacerlo. (Haykin, 1999)

La evolución del hardware ha hecho que la potencia de cálculo haya crecido de tal forma que los ordenadores hoy en día son indispensables en muchas áreas de actividad del ser humano. La computación algorítmica sin embargo no es suficiente cuando nos enfrentamos a ciertas tareas. Por ejemplo, algo tan sencillo para el ser humano como reconocer una cara de otra persona es el tipo de problema que no es tan fácil ser resuelto por la vía algorítmica.

Debido a este tipo de problemas desde finales de los 50 se ha venido investigando en un conjunto de técnicas que utilizan un enfoque diferente para resolver los problemas. Este conjunto de técnicas y herramientas se bautizó con el nombre de Inteligencia Artificial (IA), porque lo que se pretendía era que los ordenadores presentaran un comportamiento inteligente, entendiéndose por esto que supieran hacer frente a ciertos problemas de una manera similar a como lo hacen los seres humanos.

Dentro de la IA, se trabajó en dos enfoques distintos. Por un lado, se desarrolló lo que se conoce como el enfoque simbólico. Este enfoque asienta sus bases en la manipulación de símbolos en vez del mero cálculo numérico, tradicional de la computación algorítmica. La realidad se plasma por medio de una serie de reglas. Herramientas como la lógica de predicados, nos permiten manipular los símbolos y las reglas para obtener nuevas reglas. Este enfoque se presta a ser muy útil en ciertos tipos de problemas aunque en general tiene la desventaja de que a la hora de buscar la solución a un determinado problema los métodos de deducción presentan una explosión combinatoria que hace que requiera bastante tiempo de cálculo.

El otro enfoque tradicional es el enfoque conexionista y es donde se encuadran las redes neuronales. La idea aquí es desarrollar un sistema formado por pequeñas unidades de cálculo en cierta medida muy simples y hacer mediante conexiones entre ellas, que todo el conjunto sea capaz de resolver cierta clase de problemas.

2.2.1.4.2. Redes Neuronales

La idea que animó el modelo conexionista fue la de imitar el sistema de computación más complejo de los que se conocen hasta ahora, que es el cerebro. El cerebro está formado por

millones de células llamadas neuronas. Estas neuronas son unos procesadores de información muy sencillos con un canal de entrada de información (dendritas), un órgano de cómputo (soma) y un canal de salida de información (axón).




Ilustración 31 – Representación de una neurona biológica

De esta forma, las RNA imitan en cierto modo la estructura y física y el modo de operación de un cerebro. Teniendo en cuenta que el cerebro presenta las cualidades de procesamiento paralelo, procesamiento distribuido y adaptabilidad, un sistema RNA tiene también estas características.

El sistema resulta ser intrínsecamente paralelo porque está formado por unidades elementales de procesamiento llamadas neuronas. Cada neurona realiza un tipo de procesamiento muy simple.

El sistema es distribuido. Esto quiere decir que la información no se almacena localmente en ciertas zonas concretas de la RNA sino que se halla presente por toda ella, en concreto, se almacena en la sinapsis entre las neuronas. De igual forma, la computación es también distribuida. Al calcular la respuesta de la red neuronal, intervienen todos y cada uno de los procesadores elementales, los cuales se hallan distribuidos por toda la arquitectura de la red. Además. Este carácter distribuido hace que la red presente tolerancia a fallos (si se pierde una parte de las neuronas no se pierde toda la información)

Una red neuronal presenta además un grado de adaptabilidad que se concreta en las capacidades de aprendizaje y generalización. Por aprendizaje entendemos la capacidad para recoger información de las experiencias y utilizarlas para actuar ante situaciones futuras. Íntimamente relacionada con el aprendizaje está la generalización, que podría definirse como la capacidad para abstraer la información útil, más allá de los casos particulares. De esta manera, la RNA es capaz de responder ante casos desconocidos (Santana, 2006).

2.2.1.4.3. La Neurona Artificial

La unidad básica de una RNA es la neurona. Aunque hay varios tipos de neuronas diferentes, la más común es la de tipo McCulloch-Pitts. En la siguiente figura puede verse una representación de la misma




Ilustración 32 – Representación de una neurona artificial tipo McCulloch-Pitts

Una neurona artificial es un procesador elemental, en el sentido de que procesa un vector $x(x_1, x_2, \dots, x_N)$ de entradas y produce una respuesta o salida única. Los elementos clave de una neurona artificial los podemos ver en la figura anterior y son los siguientes:

- Las entradas que reciben los datos de otras neuronas. En una neurona biológica corresponderían a las dendritas
- Los pesos sinápticos w_{ij} . Al igual que en una neurona biológica se establecen sinápsis entre las dendritas de una neurona y el axón de otra, en una neurona artificial a las entradas que vienen de otras neuronas se les asigna un peso, un factor de importancia. Este peso, que es un número, se

modifica durante el entrenamiento de la red neuronal, y es aquí por tanto donde se almacena la información que hará que la red sirva para un propósito u otro.

- Una regla de propagación. Con esas entradas y los pesos sinápticos, se suele hacer algún tipo de operación para obtener el valor del potencial post-sináptico (valor que es función de las entradas y los pesos y que es el que se utiliza en último término para realizar el procesamiento). Una de las operaciones más comunes es sumar las entradas, pero teniendo en cuenta la importancia de cada una (el peso sináptico asociado a cada entrada). Es lo que se llama suma ponderada, aunque otras operaciones también son posibles.

$$h_i(t) = \sum_j w_{ij} x_j$$

La otra regla de propagación más habitual es la distancia euclídea.

- Una función de activación. El valor obtenido con la regla de propagación, se filtra a través de una función conocida como función de activación y es la que nos da la salida de la neurona. Según para lo que se desee entrenar la red neuronal, se suele escoger una función de activación u otra en ciertas neuronas de la red. En la siguiente tabla se muestran las funciones de activación más usuales


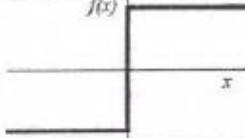
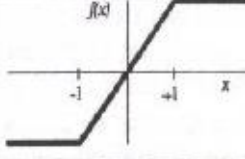
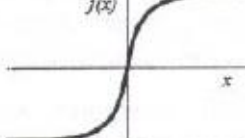
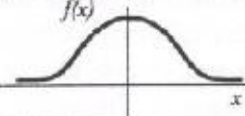
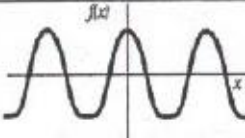
	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Tabla 1 – Funciones de activación más usuales

En muchas ocasiones la razón para la aplicación de una función de activación distinta de la identidad surge de la necesidad de que las neuronas produzcan una salida acotada. Esto desde un punto de vista de similitud con el sistema biológico, no es tan descabellado, ya que las respuestas de las neuronas biológicas están acotadas en amplitud. Además cada neurona tiene asociado un número denominado bias o umbral, que puede verse como un número que indica a partir de qué valor del potencial post-sináptico la neurona produce una salida significativa.

2.2.1.4.3.1. Arquitectura de una RNA

Desde un punto de vista matemático, se puede ver una red neuronal como un grafo dirigido y ponderado donde cada uno de los nodos son neuronas artificiales y los arcos que unen los nodos son las conexiones sinápticas. Al ser dirigido, los arcos son unidireccionales. ¿Qué quiere decir esto? En el lenguaje de neuronas y conexiones significa que la información se propaga en un único sentido, desde una neurona pre-sináptica (neurona origen) a una neurona post-sináptica (neurona destino).

Por otra parte es ponderado, lo que significa que las conexiones tienen asociado un número real, un peso, que indica la importancia de esa conexión con respecto al resto de las conexiones. Si dicho peso es positivo la conexión se dice que es excitadora, mientras que si es negativa se dice que es inhibidora.

Lo usual es que las neuronas se agrupen en capas de manera que una RNA está formada por varias capas de neuronas. Aunque todas las capas son conjuntos de neuronas, según la función que desempeñan, suelen recibir un nombre específico. Las más comunes son las siguientes:

- Capa de entrada: las neuronas de la capa de entrada, reciben los datos que se proporcionan a la RNA para que los procese.
- Capas ocultas: estas capas introducen grados de libertad adicionales en la RNA. El número de ellas puede depender del tipo de red que estemos considerando. Este tipo de capas realiza gran parte del procesamiento.
- Capa de salida: Esta capa proporciona la respuesta de la red neuronal. Normalmente también realiza parte del procesamiento.

2.2.1.4.4. Clasificación de las RNA

Según el criterio que escojamos para clasificar las RNA tendremos una clasificación u otra. Lo más común es usar la arquitectura y el tipo de aprendizaje como criterios de clasificación.

Si nos fijamos en la arquitectura podemos tener dos posibilidades distintas. Si la arquitectura de la red no presenta ciclos, es decir, no se puede trazar un camino de una neurona a sí misma, la red se llama unidireccional (feedforward).

Por el contrario, si podemos trazar un camino de una neurona a sí misma la arquitectura presenta ciclos. Este tipo de redes se denominan recurrentes o realimentados (recurrent).




Ilustración 33 – Representación de redes unidireccionales y realimentadas

El otro criterio más habitual para clasificar las redes neuronales es el tipo de aprendizaje que se utilice. Hay cuatro clases de aprendizaje distintos:

a. Aprendizaje supervisado: En este tipo de aprendizaje se le proporciona a la RNA una serie de ejemplos consistentes en unos patrones de entrada, junto con la salida que debería dar la red. El

proceso de entrenamiento consiste en el ajuste de los pesos para que la salida de la red sea lo más parecida posible a la salida deseada. Es por ello que en cada iteración se use alguna función que nos dé cuenta del error o el grado de acierto que está cometiendo la red.

b. Aprendizaje no supervisado o auto organizado: En este tipo de aprendizaje se presenta a la red una serie de ejemplos pero no se presenta la respuesta deseada. Lo que hace la RNA es reconocer regularidades en el conjunto de entradas, es decir, estimar una función densidad de probabilidad $p(\mathbf{x})$ que describe la distribución de patrones \mathbf{x} en el espacio de entrada R^n .

c. Aprendizaje Híbrido: Es una mezcla de los anteriores. Unas capas de la red tienen un aprendizaje supervisado y otras capas de la red tienen un aprendizaje de tipo no supervisado.

d. Aprendizaje reforzado (reinforcement learning): Es un aprendizaje con características del supervisado y con características del auto organizado. No se proporciona una salida deseada, pero sí que se le indica a la red en cierta medida el error que comete, aunque es un error global.

2.2.1.4.4.1. El perceptrón multicapa (MLP)

Este es uno de los tipos de redes más comunes. Se basa en otra red más simple llamada perceptrón simple solo que el número de capas ocultas puede ser mayor o igual que una. Es una red unidireccional (feedforward). La arquitectura típica de esta red es la siguiente:




Ilustración 34 – Representación de un perceptrón multicapa (MLP)

Las neuronas de la capa oculta usan como regla de propagación la suma ponderada de las entradas con los pesos sinápticos w_{ij} y sobre esa suma ponderada se aplica una función de transferencia de tipo sigmoide, que es acotada en respuesta.




Ilustración 35 – Forma funcional de una sigmoide

El aprendizaje que se suele usar en este tipo de redes recibe el nombre de retro propagación del error (backpropagation).

Como función de costo global, se usa el error cuadrático medio. Es decir, que dado un par $(\mathbf{x}_k, \mathbf{d}_k)$ correspondiente a la entrada k de los datos de entrenamiento y salida deseada asociada se calcula la cantidad:

$$E(w_{ij}, \theta_j, w_{kj}', \theta_k') = \frac{1}{2} \sum_p \sum_k \left(d_k^p - \left(\sum_j w_{kj}' y_j^p - \theta_k' \right) \right)^2$$

que vemos que es la suma de los errores parciales debido a cada patrón (índice p), resultantes de la diferencia entre la salida deseada d_p y la salida que da la red $f(\cdot)$ ante el vector de entrada \mathbf{x}_k .

Si estas salidas son muy diferentes de las salidas deseadas, el error cuadrático medio será grande. “ f ” es la función de activación de las neuronas de la capa de salida e “ y ” la salida que proporcionan las neuronas de la última capa oculta.

Sobre esta función de costo global se aplica algún procedimiento de minimización. En el caso del MLP se hace mediante un descenso por gradiente. Las expresiones que resultan aplicando la regla de la cadena se denominan “términos delta” y son las siguientes:

$$\delta w_{kj}' = -\varepsilon \cdot \frac{\partial E}{\partial w_{kj}}$$

$$\delta w_{ji}' = -\varepsilon \cdot \frac{\partial E}{\partial w_{ji}}$$

$$\delta w_{kj}' = \varepsilon \cdot \sum_p \Delta_k^p y_j^p \xrightarrow{con} \Delta_k^p = [d_k^p - f(v_k'^p)] \frac{\partial f(v_k'^p)}{\partial v_k'^p}$$

$$\delta w_{ij}' = \varepsilon \cdot \sum_p \Delta_j^p x_i^p \xrightarrow{con} \Delta_j^p = \left(\sum_k \Delta_k^p w_{kj}' \right) \frac{\partial f(v_j'^p)}{\partial v_j'^p}$$

Siendo y_k las salidas de la capa oculta.

El aprendizaje por backpropagation queda como sigue:

1. Inicializar los pesos y los umbrales iniciales de cada neurona. Hay varias posibilidades de inicialización siendo las más comunes las que introducen valores aleatorios pequeños.
2. Para cada patrón del conjunto de los datos de entrenamiento
 - a. Obtener la respuesta de la red ante ese patrón. Esta parte se consigue propagando la entrada hacia adelante, ya que este tipo de red es feedforward. Las salidas de una capa sirven como entrada a las neuronas de la capa siguiente, procesándolas de acuerdo a la regla de propagación y la función de activación correspondientes.
 - b. Calcular los errores asociados según la ecuación de los términos delta.
 - c. Calcular los incrementos parciales (sumandos de los sumatorios). Estos incrementos dependen de los errores calculados en 2.b.
3. Calcular el incremento total, para todos los patrones, de los pesos y los umbrales según las expresiones en la ecuación de los términos delta.

4. Actualizar pesos y umbrales
5. Calcular el error actual y volver al paso 2 si no es satisfactorio.

2.2.1.4.4.2. Redes auto-organizadas. Redes SOFM

En este tipo de redes el entrenamiento o aprendizaje es diferente al de las redes con entrenamiento supervisado. A la red no se le suministra junto a los patrones de entrenamiento, una salida deseada. Lo que hará la red es encontrar regularidades o clases en los datos de entrada, y modificar sus pesos para ser capaz de reconocer estas regularidades o clases.

Uno de los tipos de redes que pertenece a esta familia y que se ha usado bastante son los mapas auto organizados, SOM (Self-Organizing Maps). La arquitectura típica de este tipo de mapas es la siguiente:




Ilustración 36 – Arquitectura típica de un mapa SOM

Como se puede apreciar es una red de tipo unidireccional. La red se organiza en dos capas, siendo la primera capa la formada por las neuronas de entrada. La segunda capa consiste en un array de neuronas de dos dimensiones. Como se necesitan dos índices para etiquetar cada neurona, los pesos sinápticos asociados a cada neurona tendrán tres índices (i,j,k) donde (i,j)

indican la posición de la neurona en la capa y k, la componente o conexión con cierta neurona de entrada.

En cuanto al entrenamiento, este es un ejemplo de red que utiliza un aprendizaje de tipo no supervisado. Además, cada neurona utiliza como regla de propagación una distancia de su vector de pesos sinápticos al patrón de entrada.

Otros conceptos importantes que intervienen en el proceso de aprendizaje son los conceptos de neurona ganadora y vecindad de la misma. Un algoritmo de aprendizaje muy usado con este tipo de redes es el algoritmo de Kohonen que se describe como sigue:

1. Inicialización de los pesos w_{ijk} . Hay varias opciones posibles.
2. Elección de un patrón de entre el conjunto de patrones de entrenamiento.
3. Para cada neurona del mapa, calcular la distancia euclídea entre el patrón de entrada \mathbf{x} y el vector de pesos sinápticos (ver fórmula).

$$d^2(w_{ij}, x) = \sum_k (w_{ijk} - x_k)^2$$

4. Evaluar la neurona ganadora, es decir aquella cuya distancia es la menor de todas
5. Actualizar los pesos sinápticos de la neurona ganadora y de sus vecinas según la regla:

$$\delta w_{ijk}(t) = \alpha(t) \cdot h(|i - g|, t) \cdot (x_k(t) - w_{ijk}(t))$$

alfa(t) es un factor llamado ritmo de aprendizaje que da cuenta de la importancia que la diferencia entre el patrón y los pesos tiene en el ajuste de los mismos a lo largo del proceso de aprendizaje. Hay varias posibilidades para esta función, desde un constante hasta algún tipo de función monótona decreciente con el tiempo. h es una función de vecindad que nos indica en qué medida se modifican los pesos de las neuronas vecinas. Con esto quiere decir que cuando la neurona ganadora modifica sus pesos, la vecindad de esta neurona lo hace también, en mayor o menor medida según sea la forma funcional de h. En general, las funciones empleadas para h tienen

un máximo en $|i-j|=0$ y decrecen más o menos rápido a medida que esta distancia aumenta.

6. Lo usual es fijar un número de iteraciones antes de comenzar el aprendizaje. Si no se llegó al número de iteraciones establecido previamente, se vuelve al paso 2. Sobre este número de iteraciones necesario, se suelen tomar criterios como el número de neuronas en el mapa.

2.2.1.4.4.3. Redes de función de base radial (RBF)

Este tipo de redes se caracteriza por tener un aprendizaje o entrenamiento híbrido. La arquitectura de estas redes se caracteriza por la presencia de tres capas: una de entrada, una única capa oculta y una capa de salida.





Ilustración 37 – Arquitectura típica de una red tipo RBF

Aunque la arquitectura pueda recordar a la de un MLP, la diferencia fundamental está en que las neuronas de la capa oculta en vez de calcular una suma ponderada de las entradas y aplicar una sigmoide, estas neuronas calculan la distancia euclídea entre el vector de pesos sinápticos (que recibe el nombre en este tipo de redes de centro o centroide) y la entrada (de manera casi análoga a como se hacía con los mapas SOM) y sobre esa distancia se aplica una función de tipo radial con forma gaussiana.



Capa oculta: neurona gaussiana

Ilustración 38 – Forma funcional de una curva tipo Gaussiana

Para el aprendizaje de la capa oculta, hay varios métodos, siendo uno de los más conocidos el algoritmo denominado k-medias (k-means) que es un algoritmo no supervisado de clustering. k es el número de grupos que se desea encontrar, y se corresponde con el número de neuronas de la capa oculta, que es un parámetro que hay que decidir de antemano.

El algoritmo se plantea como sigue:

1. Inicializar los pesos (los centros) en el instante inicial. Una inicialización típica es la denominada k-primeras mediante la cual los k centros se hacen iguales a las k primeras muestras del conjunto de datos de entrenamiento $\{\mathbf{x}_p\}_{p=1..N}$
 $\mathbf{c}_1 = \mathbf{x}_1$, $\mathbf{c}_2 = \mathbf{x}_2$, ... $\mathbf{c}_N = \mathbf{x}_N$,
2. En cada iteración, se calculan los dominios, es decir, se reparten las muestras entre los k centros. Esto se hace de la siguiente manera: Dada una muestra \mathbf{x}_j se calcula las distancias a cada uno de los centros \mathbf{c}_k . La muestra pertenecerá al dominio del centro cuya distancia calculada sea la menor.
3. Se calculan los nuevos centros como los promedios de los patrones de aprendizaje pertenecientes a sus dominios. Viene a ser como calcular el centro de masas de la distribución de patrones, tomando que todos pesan igual.
4. Si los valores de los centros varían respecto a la iteración anterior se vuelve al paso 2, si no, es que se alcanzó la convergencia y se finaliza el aprendizaje

Una vez fijados los valores de los centros, sólo resta ajustar las anchuras de cada neurona. Las anchuras son los parámetros sigma que aparecen en cada una de las funciones gaussianas y reciben ese nombre por su interpretación geométrica, dan una medida de cuando una muestra activa una neurona oculta para que de una salida significativa




Ilustración 39 – Centros en el espacio de las entradas

normalmente se toma el criterio de que para cada neurona se toma como valor sigma la distancia al centro más cercano.

Finalmente, se entrena la capa de salida. El entrenamiento de esta capa se suele usar un algoritmo parecido al que se usa para la capa de salida del MLP. La actualización de los pesos viene dada por la expresión:

$$z_k = \sum_j w_{kj} \phi(r_j) + \theta_k$$

$$\delta w_{kj}(t) = \varepsilon (d_k - z_k) \phi(r_j)$$

Con este fin se suele presentar todos los patrones de la muestra de entrenamiento varias veces. Cada una de estas veces recibe el nombre de época (Burgos, 2003).

2.2.1.4.4.4. Red FIR (Red Neuronal con respuesta finita al impulso)

Una red neuronal FIR se compone de neuronas FIR, las cuales toman secuencias de entrada en sus terminales, les aplican un filtro FIR, suman los resultados y lo pasan por una función de activación. La unidad estructural de este tipo de redes se muestra en la Ilustración 40 y el filtro FIR aplicado a las entradas en la Ilustración 41.

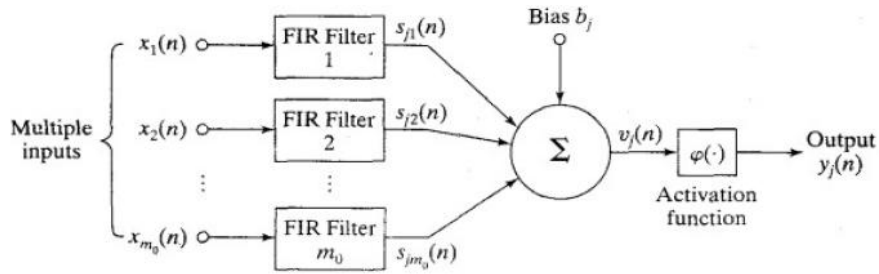


Ilustración 40 – Neurona FIR




Ilustración 41 – Filtro FIR

Puesto que el filtro FIR se aplica a los datos recibidos durante una ventana de tiempo, las redes neuronales FIR son capaces de reconocer patrones temporales y predecir secuencias. Estas redes se pueden entrenar mediante el algoritmo retro propagación temporal (Estévez, 2011).

2.2.1.4.5. Indicadores de desempeño

Para medir la calidad de las predicciones se pueden utilizar los indicadores MSPE y NMSPE.

MSPE se define como:

$$MSPE = \frac{1}{N} \sum_{i=1}^N (x_i - X_i)^2$$

Donde x_i es la predicción en tiempo i , X_i es el valor de la serie en tiempo i y N es el total de predicciones. Este indicador mide la varianza del error de la predicción.

NMSPE se define como:

$$NMSPE = \frac{\sum_{i=1}^N (x_i - X_i)^2}{\sum_{i=1}^N (x_i - X)^2}$$

Donde X es el promedio de los datos. Este indicador mide la razón de la varianza de la desviación en la predicción con la varianza respecto al promedio de datos.

3. MODELACIÓN DE REDES NEURONALES

3.1.METODOLOGÍA

Con el afán de realizar predicciones de la demanda de potencia eléctrica de Metro S.A. se implementarán redes neuronales del tipo Perceptrón Multicapa. Se escogió este tipo de red, ya que poseen la capacidad de procesar información de eventos pasados y realizar predicciones futuras, efectuando comparaciones entre las predicciones hechas y los datos reales del sistema para el instante de tiempo en que se realiza la predicción. Es así, como mediante el método de retro-propagación, las redes neuronales con multicapas van disminuyendo el error en la predicción hasta minimizarlo (Santana, 2006).




Ilustración 42 – Representación de un perceptrón multicapa (MLP)

Todo lo anterior funcionará siempre y cuando se pueda entrenar a las redes neuronales con una cantidad de datos suficientes, que permitan a la red neuronal aprender de la dinámica del sistema eléctrico de Metro S.A., de manera de poder generalizar el comportamiento de las variables eléctricas de este sistema dinámico y así permitir realizar predicciones con una certeza adecuada.

Para esta labor, se cuenta con los archivos Excel del control de demanda del sistema Eléctrico de Metro S.A., los cuales son generados automáticamente por un sistema SCADA, y poseen los datos de demanda de potencia eléctrica minuto a minuto de Metro S.A., para todos los meses de un año.

Se utilizarán los datos del año 2010, pues todas las acciones de control realizadas ese año por los operadores del control de demanda de potencia eléctrica de la empresa, fueron registradas en una bitácora. Gracias al registro, se tiene la posibilidad de discriminar los casos en que se efectuó un control de demanda y los casos en que no se efectuó control alguno. Finalmente con los datos que no poseen intervención humana, se estudiará la dinámica de Metro S.A., para determinar cómo se comportaría el sistema en los intervalos de tiempo entre las 18:00 hrs y las 20:00 hrs sin que hubiese control por parte de los operadores.

Se pretende dividir el estudio del sistema eléctrico de Metro S.A. en dos sistemas eléctricos por separado: El SEAT y el CDC-VV debido a que son sistemas separados los cuales poseen distintas características de alimentación eléctrica y de consumo. Se debe recordar que el SEAT es alimentado por las subestaciones Ochagavia y Renca y alimenta de electricidad a las líneas 1,2 y 5, mientras que el sistema CDC-VV es alimentado por las subestaciones Macul y Santa Raquel y sus consumos corresponden a los de las líneas 4 y 4A.

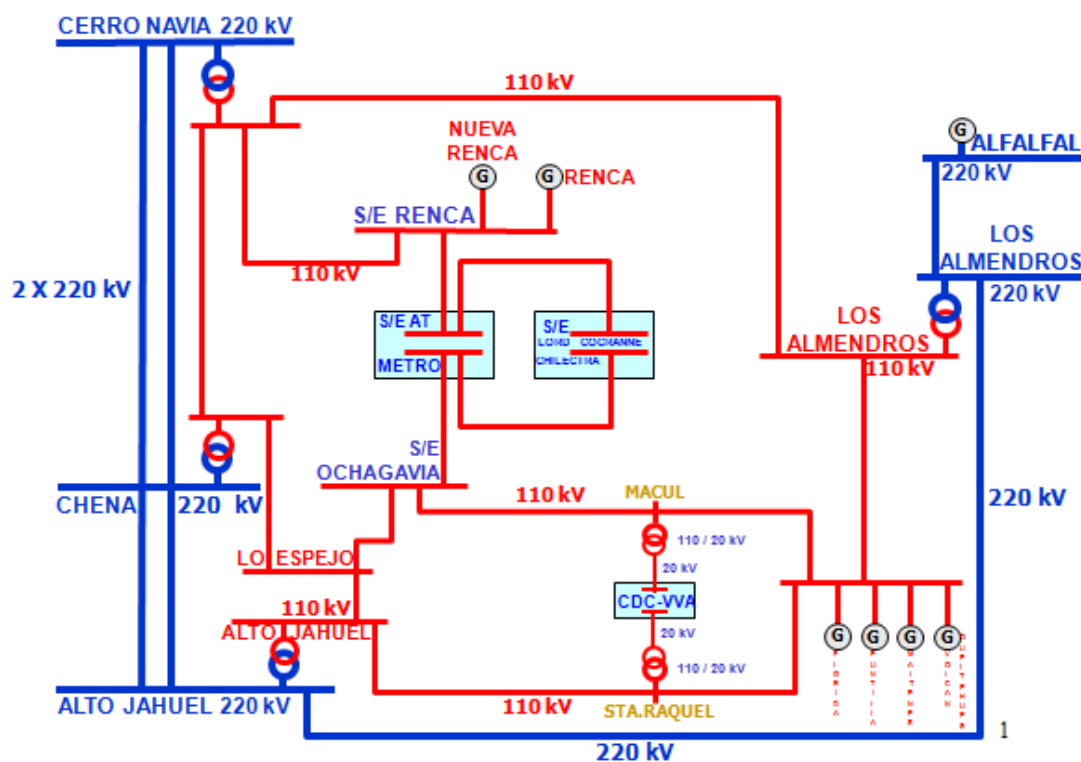


Ilustración 43 – Esquema unilineal alimentación eléctrica Metro S.A.

Para cada sistema se realizarán predicciones en el intervalo de las 18:00 a las 20:00 hrs, debido a que el control de demanda en hora punta se realiza en este horario, principalmente porque la Comisión Nacional de Energía establece que el horario punta del sistema eléctrico en Chile es entre los meses de Abril a Septiembre, entre las 18:00 y las 23:00 hrs, según el informe técnico definitivo de Octubre del año 2011 (Comisión Nacional de Energía, 2011) y, además porque entre las 18:00 y las 20:00 hrs, Metro S.A. utiliza la máxima cantidad de trenes.

Las predicciones serán cada 5 minutos, y para este fin se diseñarán 48 arquitecturas de red neuronal multicapa, 24 para el subsistema SEAT y 24 para el subsistema CDC-VV. Con las 24 redes neuronales se cubre el rango horario desde las 18:05 hasta las 20:00 hrs que se quiere predecir.

Las redes neuronales se modelarán en el software computacional Matlab 2011, el cual permite, entre otras cosas, modelar redes neuronales y realizar simulaciones que permitan a las redes modeladas realizar un aprendizaje de un determinado sistema dinámico para luego predecir series de tiempo a futuro.

Primero se diseñarán un par de redes neuronales, entrenadas con la dinámica de potencia eléctrica de Metro S.A. correspondiente al año 2010, y en particular con datos de la demanda de potencia de Metro S.A. para los meses entre Marzo y Octubre, con la finalidad de testear el funcionamiento de las redes neuronales en Matlab, y ver cómo se comportan prediciendo la dinámica de Metro. Se incluyeron los meses de Marzo y Octubre debido a que poseen un comportamiento similar a los meses de Abril, Mayo, Junio, Julio, Agosto y Septiembre correspondiente a los meses de punta del Sistema Interconectado Central.

Cuando las redes neuronales hayan sido entrenadas, se obtendrán gráficos y observaciones que permitan verificar la certeza con la cual se realizan las predicciones. Luego de validar cada red neuronal por separado, se deberá realizar una conversión que permita actualizar los datos desde el 2010 hasta el 2012. Para esto se plantea la siguiente hipótesis:

La diferencia que existe entre un año y otro radica principalmente en la potencia que se utilice para alumbrado y fuerza (Subestaciones de alumbrado y fuerza - SAF) más la potencia que se utilice para tracción (Subestaciones rectificadoras - SER). Cabe destacar que los consumos SAF son aproximadamente un 20% del consumo total de un sistema, y además se podrían considerar estáticos debido a su baja aleatoriedad y a su baja importancia dentro de los consumos del sistema. Los consumos de tracción, alimentados por las subestaciones de rectificación (SER) varían de acuerdo a la cantidad de trenes que circulen por las líneas. Por lo tanto, si se considera un factor de expansión que implique tanto la expansión en SAF como en trenes para el año 2012 respecto al 2010, las redes neuronales podrían realizar predicciones

acertadas para el año actual, debido a que la dinámica de Metro seguirá siendo la misma, principalmente debido al control que realizan los operadores de Metro para que exista una regularidad en el tráfico de trenes por las líneas.

Es así, como se diseñarán entonces 48 redes neuronales entrenadas con la dinámica de potencia eléctrica de Metro S.A. correspondiente al año 2012, y cabe agregar que se utilizará el intervalo desde las 16:00 hrs hasta las 20:00 hrs, con datos de demanda de potencia eléctrica cada 5 minutos para el entrenamiento de las redes neuronales.

Finalmente se deberá realizar una prueba en terreno de cómo funcionarán los modelos de redes neuronales para predecir los datos de demanda de potencia eléctrica de Metro para el año vigente, y así confirmar que las predicciones de los distintos modelos sean aceptables y por consiguiente, permitan realizar un control de demanda de potencia eléctrica de Metro S.A. en horario punta, más eficiente.

3.2.MODELO DE RED NEURONAL

Como se mencionó anteriormente, se utilizará el modelo de redes neuronales con multicapas para predecir la demanda de potencia eléctrica de Metro S.A. en el intervalo 18:05 a 20:00 hrs. Para eso se cuenta con el toolbox de redes neuronales de Matlab 2011, el cual permitirá programar cada red, entrenar la red con la información de las hojas Excel proporcionadas por el sistema SCADA, y luego realizar simulaciones para distintas arquitecturas dentro de las cuales se buscará aquellas que posean el menor error en la predicción.

El flujo de trabajo para el proceso general de diseño de una red neuronal contiene los siguientes 7 pasos primarios:

- Coleccionar la información
- Crear la red

- Configurar la red
- Inicializar los pesos y los umbrales
- Entrenar a la red
- Validar la red (análisis post entrenamiento)
- Usar la red

Antes de comenzar el proceso de diseño de la red, primero se recolecta la información y se preparan los datos del sistema. Es generalmente complicado incorporar conocimiento previo a una red neuronal, de esta forma la red solo puede ser lo suficientemente certera en sus predicciones como lo son los datos que se utilizaron para entrenar a la red (Matlab, 2011).

Es importante que los datos cubran el rango de entradas para la cual la red será utilizada. Las redes multicapas pueden ser entrenadas para generalizar bien dentro del rango de entradas para las cuales han sido entrenadas. Sin embargo, ellas no tienen la habilidad de extrapolar de manera certera datos fuera de este rango, así que es importante que los datos de entrenamiento cubran el rango completo de la entrada.

Después que los datos sean recolectados, se deben realizar dos pasos antes de entrenar a la red: Los datos deben ser pre-procesados y ellos necesitan ser divididos en subconjuntos.

El entrenamiento de una red puede ser más eficiente si se realizan ciertos pasos de pre-procesamiento en las entradas y salidas objetivos de la red. Por ejemplo, en redes neuronales multicapas, la función sigmoidea de transferencia es usualmente utilizada en las capas ocultas. Estas funciones se saturan cuando las entradas de la red son mayores que $(\exp(-3)=0.05)$. Si esto ocurre al comienzo del proceso de entrenamiento, los gradientes serán muy pequeños, y el entrenamiento de la red será muy lento. En la primera capa de la red, la entrada de la red se obtiene con la multiplicación de la entrada por el peso más el umbral. Si la entrada es muy grande, entonces el peso debe ser muy pequeño para prevenir la saturación de la función de transferencia. Es una práctica estándar normalizar las entradas antes de aplicárselas a la red.




Ilustración 44 – Objeto Red Neuronal en Matlab

Al entrenar redes multicapa, la práctica general es primero dividir la información en tres subconjuntos. El primer subconjunto es el set de entrenamiento, el cual es utilizado para calcular el gradiente y actualizar los pesos y umbrales de la red. El segundo subconjunto es el de validación. El error en el subconjunto de validación es monitoreado durante el proceso de entrenamiento. El error de validación disminuye normalmente durante la fase inicial del entrenamiento, tal como lo hace el error del set de entrenamiento. Sin embargo, cuando la red comienza a hacer calzar los datos, el error en el conjunto de validación típicamente comienza a crecer. Los pesos y los umbrales de la red son guardados en el mínimo error del set de validación.

Luego de haber recolectado la información, el siguiente paso en el entrenamiento de la red es crear el objeto red en Matlab. Para ello, se deberán definir: las entradas (retardos) de la red; las configuraciones para las distintas capas de entrada, interna y salida; la función de transferencia; el algoritmo de entrenamiento; el algoritmo de aprendizaje y el método de evaluación.

Si se requieren N entradas, se deberá configurar una matriz de Nx2 con los valores mínimo y máximo permitido para cada entrada. Para el caso de las redes neuronales que predecirán la demanda de potencia eléctrica de Metro, se calculan los mínimos y máximos de los datos de entrada normalizados con la función minmax y se multiplica por 2, en caso que alguna vez ingresaran datos ligeramente fuera del intervalo. La sintaxis es

```
entradas = minmax(pn)*2;
```

Donde p_n es una matriz de $N \times M$ donde N es el número de entradas o retardos en la red neuronal y M es la cantidad de ejemplos que se ingresan a la red para entrenarla.

Si se requieren C capas, hay que suministrar un vector de largo C , con el número de neuronas para cada capa. El primer elemento corresponde a la primera capa oculta y el último a la capa de salida. Por ejemplo, una red neuronal de 3 capas, con 10 neuronas en la capa de entrada, 5 neuronas en la capa interna y una neurona en la capa de salida se debiese ingresar como:

```
capas = [10 5 1];
```

A las neuronas de cada capa se les asigna una función de transferencia. Para esto se suministra una lista de strings {tf-1 tf-2 ... tf-N}, donde “tf-i” corresponde a la función de transferencia de las neuronas de la capa “i” y puede ser: 'tansig' (tangente sigmoidal); 'logsig' (logaritmo sigmoidal) o 'purelin' (lineal). Un ejemplo para el caso anterior cuando se tenía 3 capas podría ser:

```
funcion_de_transferencia={'tansig' 'tansig' 'purelin'};
```




Ilustración 45 – Funciones de transferencia en Matlab

Para indicar el algoritmo de entrenamiento en Matlab, este se explicita con un string el cual puede ser: 'traingda'; 'traingdm'; 'traingdx'; 'trainlm'; 'traingd', 'trainbr' entre otros (ver bibliografía, manual del toolbox de redes neuronales de Matlab). Cabe destacar que 'trainlm' es el más rápido, aunque demanda más memoria del computador. La sintaxis de declaración de la variable podría ser:

```
algoritmo_de_entrenamiento='trainlm';
```

El algoritmo de aprendizaje, al igual que el algoritmo de entrenamiento, se debe especificar con un string. Dentro de los principales algoritmos en Matlab se encuentran: 'learngdm', 'learnh', 'learnk' (ver la bibliografía, manual del toolbox de redes neuronales en Matlab). La declaración de la variable podría ser:

```
algoritmo_de_aprendizaje='learngdm';
```

Existen tres métodos de evaluación en Matlab para comparar las predicciones realizadas por una red neuronal con los datos reales en el instante de predicción. Los métodos son: 'mse' (mean squared error), 'mae' (mean absolute error) y 'sse' (sum squared error). Un ejemplo de la sintaxis de declaración de esta variable podría ser:

```
metodo_de_evaluacion='mse';
```

Habiendo definido las entradas, capas, función de transferencia, algoritmo de entrenamiento, algoritmo de aprendizaje y método de evaluación, se puede crear la red mediante el comando "newff" el cual devuelve un objeto red neuronal multicapa. Utilizando la misma sintaxis con las cuales se definieron las distintas variables de la red neuronal en los ejemplos anteriores, para creación de la red neuronal podría usarse lo siguiente:

```
net = newff(entradas, capas, funcion_de_transferencia, algoritmo_de_entrenamiento,  
           Algoritmo_de_aprendizaje, metodo_de_evaluacion);
```

Después de haber creado el objeto red neuronal, este se debe inicializar. Para este fin, se utiliza la siguiente línea de comandos:

```
net = init(net);
```

Sobre la red creada se pueden ajustar parámetros, como la tasa de aprendizaje, momentum, número máximo de épocas, gradiente mínimo, número máximo de aumento del error en el

conjunto de validación, etc. A continuación, y a modo de ejemplo, se mostrará cómo se inicializa algunas de estas variables.

Ajustar número máximo de épocas a 500. Esto hace que la retro-propagación del error, un proceso iterativo que permite reducir el error de las predicciones, no llegue más allá de las 500 iteraciones. Para esto, se utiliza la siguiente sintaxis:

```
net.trainParam.epochs = 500;
```

Fijar la tasa de aprendizaje en 0.1. Una tasa mayor acelera el aprendizaje de la red neuronal, sin embargo, se corre el riesgo de oscilaciones en torno al error mínimo y a que no se converga al óptimo. La sintaxis es:

```
net.trainParam.lr=0.1;
```

Fijar momentum en 0.3. Ayuda a un aprendizaje más rápido. Sin embargo, si el momentum es muy grande, podría obtenerse una solución que se mantiene oscilando en torno a un mínimo local del error sin converger al mínimo. La sintaxis es:

```
net.trainParam.mc=0.3;
```

Fijar el número máximo de fallas de validación en 10. Si se supera este número el entrenamiento se detiene. Se debe recordar que en un comienzo el error de entrenamiento decrece junto al error de validación, pero cuando se está cerca del mínimo error de entrenamiento, el error de validación comienza a crecer. Para lo anterior, se puede ejecutar el siguiente código:

```
net.trainParam.max_fail=10;
```

Fijar el gradiente mínimo en $1e-15$. Si el gradiente es menor, el entrenamiento se detiene. Esto permite buscar el mínimo cerca de la región donde el gradiente se hace cero, que efectivamente es el punto donde se tendrá el mínimo error.

```
net.trainParam.min_grad=1e-15;
```

Fijar el tiempo máximo en segundos en infinito, permitirá realizar el entrenamiento de la red neuronal de forma permanente y se detendrá sólo por fijaciones como las expuestas con anterioridad y que se refieren a minimizar el error y no a minimizar el tiempo de entrenamiento.

```
net.trainParam.time=inf;
```

Fijar el error objetivo en cero. Si el error iguala este valor o es menor, el entrenamiento se detiene. La sentencia para este fin es:

```
net.trainParam.goal=0;
```

Particionar los datos. Tal como se mencionó en un comienzo, los datos de entrada se deben dividir en subconjuntos de entrenamiento, validación y test. Los métodos de particionado son: 'dividerand' (aleatorio); 'divideblock' (bloques); 'divideint' (intercruzado) y 'divideind'(por índice). Para el ejemplo se usará 'dividerand'

```
net.divideFcn='dividerand';
```

Fijar la fracción de datos para entrenamiento, validación y test. Por ejemplo, se puede utilizar un 60% de los datos para entrenamiento, un 20% de los datos para validación y un 20% de los datos para test. Esto se realiza de la siguiente forma:

```
net.divideParam.trainRatio=0.6;
```

```
net.divideParam.valRatio=0.2;
```

```
net.divideParam.testRatio=0.2;
```


Finalmente, y luego de haber ajustado los parámetros de la red neuronal, ya inicializada, se procede al entrenamiento. Para entrenar se usa el comando `train`, el cual requiere de ejemplos de entradas y salidas. Siguiendo con el ejemplo en cuestión, y recordando que se definió el vector de entradas en función de `pn`, donde `pn` es una matriz de $N \times M$ donde N es el número de entradas o retardos en la red neuronal y M es la cantidad de ejemplos que se ingresan a la red para entrenarla, se tendrá la siguiente sentencia para entrenar a la red neuronal.

```
net=train(net,pn,tn);
```

Donde `tn` es una matriz de $1 \times M$ que contiene los M ejemplos de datos reales en el instante de tiempo en que se quiere realizar la predicción. Así, “`pn`” es la matriz con los ejemplos de entrada de la red neuronal y “`tn`” es la matriz con los ejemplos de salida de la red.

Luego de entrenar a la red, ya se pueden realizar simulaciones. Para simular se usa el comando `sim`, el cual recibe la red neuronal y una matriz con los datos de entrada, entregando una matriz con las salidas. La sintaxis es:

```
y=sim(net,pn);
```

A continuación se mostrarán los resultados de ingresar los datos desde las 16:00 hasta las 18:35 hrs del sistema SEAT al software Matlab, para realizar una predicción a las 18:40 de la demanda de potencia eléctrica de este sistema, el cual abastece de energía a las líneas 1,2 y 5. Se utilizaron las fijaciones de variables mostradas en el ejemplo anterior para la creación y el entrenamiento de la red neuronal. Los resultados de las predicciones son los siguientes:




Ilustración 46 – Predicción a las 18:40 hrs en el SEAT

3.3.SIMULACIONES

3.3.1.Datos de entrada

Se quiere realizar la predicción de la demanda eléctrica de potencia de Metro S.A. en tiempo real, para el horario de punta del sistema, esto es entre las 18:00 y las 20:00 hrs. Para ello, se cuenta con la información entregada por el sistema automático SCADA del control de demanda de potencia del sistema, el cual entrega un archivo Excel con la información de potencia minuto a minuto que demanda Metro.

Para una modelación óptima del sistema eléctrico de Metro, se clasificará la información en los dos subsistemas existentes a la fecha: El SEAT y CDC-VV. Como se ha mencionado con anterioridad, el SEAT es el encargado de dar energía a las líneas 1, 2 y 5, mientras que el CDC-VV tiene como consumos a las líneas 4 y 4A.

El rango horario óptimo determinado para presentar información a las redes neuronales, antes de entrar en el horario punta, es entre las 16:00 y las 18:00 hrs. Se tendrán 25 muestras de demanda de potencia para cada sistema, muestras cada 5 minutos en el intervalo recién

mencionado, para entrenar a la red neuronal con la dinámica del sistema antes del horario en el cual se realizarán las predicciones.

Si se toma en cuenta el horario punta, entre las 18:05 y las 20:00 hrs, y en ese rango se toman muestras de la demanda de potencia eléctrica de uno de los sistemas, cada 5 minutos, entonces se tendrán 24 muestras. Por esta razón, se crearán 24 redes neuronales para cada sistema. Cada red neuronal será capaz de predecir la demanda de potencia eléctrica de un sistema en un horario en particular entre las 18:05 y las 20:00 hrs, correspondiente a la muestra para la cual se diseñó la red neuronal.

Se debe tener en cuenta que en el año vigente, en el horario entre las 18:05 y las 20:00 hrs, se realiza control de demanda de potencia eléctrica por parte de los operadores del control de demanda, en el 7mo piso del edificio SEAT perteneciente a Metro S.A. Debido a esto, es que los datos pueden estar contaminados, es decir, que no reflejen el sistema dinámico natural de Metro S.A., sino más bien, un sistema intervenido por la mano del hombre.

A pesar de lo anterior, y como se explicó en la metodología para la resolución de este problema de Ingeniería, se utilizarán datos del año 2010 los cuales no poseen un control externo al sistema. Se estudiarán los días de semana, excluyendo los festivos, de los meses pertenecientes al intervalo Marzo-Octubre, debido a que poseen un consumo similar de potencia eléctrica entre ellos y además reflejan fielmente el consumo que se tiene en los meses de punta definidos por la Comisión Nacional de Energía (Abril a Octubre).

Cabe destacar, que el control que se realiza actualmente consiste, principalmente, en reducir la velocidad de los trenes por una vía de una línea en particular. Al reducir la velocidad se disminuye la potencia mecánica que deben ejercer los motores para mover los trenes a esas velocidades, y por consiguiente, se reduce la demanda de potencia eléctrica del sistema.

Los principales modos de control son:

“T+4 en una vía” que consiste en la reducción automática de la velocidad de los trenes por una vía de una línea en particular, de manera tal que los trenes demoren 4 segundos más en llegar a la estación siguiente, en comparación a una operación normal.

“T+4 en las dos vías” que consiste en la reducción automática de la velocidad de los trenes por ambas vías de una línea en particular, de manera tal que los trenes demoren 4 segundos más en llegar a la estación siguiente, en comparación a una operación normal.

Datos estadísticos proporcionados por expertos en la operación del control de demanda de potencia eléctrica de Metro S.A. indican que la aplicación de una medida T+4 en 1 vía para las 5 líneas de metro que existen en la actualidad, tiene como efecto la reducción de 2 MW de potencia al cabo de 3 a 4 minutos. Asimismo, la aplicación de una medida T+4 en ambas vías para la totalidad de las líneas de Metro, tiene como efecto la reducción de 3,5 a 4 MW de potencia eléctrica al cabo de 3 a 4 minutos.

Si se toma en cuenta que para el año 2012 se tendrá que la porción de la demanda de potencia eléctrica de Metro S.A. correspondiente a los consumos del subsistema SEAT alcanzarán un 78,1% y para el CDC Vicente Valdés un 21,9%, entonces con estos porcentajes se podrá calcular los efectos que tiene una aplicación de T+4 en 1 o dos vías para cada subsistema por separado, simplemente realizando el producto de la disminución de potencia total por el porcentaje correspondiente.

3.3.2.Resultados para las predicciones del año 2010

A continuación se presentará un par de ejemplos de redes neuronales que predecirán la demanda de potencia eléctrica de ambos subsistemas, para ver la funcionalidad de las redes en la predicción de la dinámica de Metro S.A correspondiente al año 2010.

3.3.2.1. Centro de Distribución de Carga – Vicente Valdés (CDC-VV), año 2010.

3.3.2.1.1. Predicción a las 18:30 hrs.

Para el entrenamiento de la red neuronal que se muestra a continuación, se ingresaron datos cada 15 minutos desde las 14:00 hrs hasta las 18:15 hrs y se busca obtener una predicción de la demanda de potencia eléctrica del sistema CDC-VV a las 18:30 hrs.




Ilustración 47 – Arquitectura de la red neuronal.

En la Ilustración 47 se puede apreciar las capas de entrada, intermedia y de salida de la red neuronal que se utilizó para realizar las predicciones de la demanda de potencia eléctrica del sistema CDC-VV de Metro S.A. En este caso, se utilizaron 17 neuronas en la capa de entrada, 5 en la capa intermedia y 1 para la salida.

Los resultados de las predicciones se muestran a continuación




Ilustración 48 – Resultados de las predicciones

En el gráfico de la derecha, se puede ver la superposición entre los valores reales del sistema a las 18:30 hrs y los valores predichos para ese instante de tiempo. Existe un error perceptible a la vista, el cual se muestra en las siguientes ilustraciones. En el eje de las ordenadas está graficada la potencia en kW multiplicadas por un factor 10^4 , y en el eje de las abscisas se tienen los distintos días de la semana que se utilizaron como muestras para realizar la predicción a las 18:30 hrs. En este caso se utilizaron 120 días entre los meses de Marzo y Octubre, contando sólo días de semana hábiles.




Ilustración 49 – (Izq.) Error absoluto de la predicción - (Der.) Error porcentual de las predicciones.

En la Ilustración 49 se puede visualizar el error de las predicciones respecto de los valores reales a predecir. En rojo se grafica el promedio para el intervalo de la muestra. En el error porcentual, el valor real de potencia que se debía predecir se toma como el 100 por ciento.

Sin embargo, se agregará el error porcentual respecto a otra medida. La aplicación de los modos T+4 en una vía y T+4 en dos vías, nos indican que estos son las medidas de solución que se utilizan en Metro para disminuir la demanda de potencia eléctrica. Por esta razón, es que se vuelve interesante graficar el error de la predicción respecto a la aplicación de un T+4 en 1 o 2 vías, para comparar el error de las predicciones vs los efectos que tienen las medidas de solución. Estos datos permitirán saber si la medida de solución es suficiente para paliar el error en la predicción.

Se sabe que la aplicación de T+4 en 1 vía para las 5 líneas de Metro, reduce la demanda de potencia de Metro en 2 MW. Además, los cálculos realizados para los porcentajes de consumo del SEAT y del CDC-VV, arrojaron como resultados un 78,1% y un 21,9% respectivamente. Se tendrá entonces que el efecto de aplicar un T+4 en 1 vía para las líneas del SEAT, 1,2 y 5 será de 1950 [kW] y para el CDC-VV será de 545 [kW].

Análogamente, se tendrá que la medida T+4 en ambas vías producirá una disminución en la demanda de potencia eléctrica del SEAT en 2730 [kW] y para el CDC-VV la disminución será de 765 [kW]. Esto se obtuvo tomando en cuenta que para la totalidad de Metro, se tiene una disminución de 3500 [kW] al aplicar T+4 en ambas vías de las 5 líneas de Metro.

A continuación se pueden visualizar los gráficos mencionados recientemente.




Ilustración 50 – (Izq.) Error porcentual vs T+4 en 1 vía. - (Der.) Error porcentual vs T+4 en 2 vías.

Se puede apreciar que el error promedio está sobre el 100% para ambas medidas control de demanda de potencia. Si se analiza la Ilustración 48, que muestra los valores reales a predecir, se podrá ver un peak negativo de aproximadamente 1×10^4 [kW], es decir, 10 [MW]. Este valor se escapa del resto de las medidas, debido a que es una aleatoriedad del sistema dinámico de Metro. A continuación, se mostrarán los resultados de la misma arquitectura de red, pero en este caso se eliminará esta aleatoriedad del conjunto de entrenamiento. Los resultados fueron los siguientes.




Ilustración 51 – Resultados de las predicciones. Conjunto de entrenamiento sin la aleatoriedad.

Se puede ver que en este caso se tuvieron mejores resultados. Claramente la curva de predicción sigue a la curva real de demanda de potencia eléctrica. Los errores que se tuvieron para esta red se visualizan en las siguientes ilustraciones.




Ilustración 52 – (Izq.) Error absoluto de la predicción - (Der.) Error porcentual de las predicciones.

El error porcentual disminuyó a un 2,5% aproximadamente. El error absoluto está bajo los 500 [kW] de promedio, sin embargo se deben ver los resultados contrastados con las medidas de control de la potencia. Estos se muestran a continuación.




Ilustración 53 – (Izq.) Error porcentual vs T+4 en 1 vía. - (Der.) Error porcentual vs T+4 en 2 vías.

En esta ocasión, los resultados estuvieron bajo el 100% en ambos casos. Esto quiere decir que en promedio, el error de las predicciones podrá ser solucionado por la medida de control que se posee, esto debido a que el efecto de aplicar la medida de solución produce una disminución de la demanda de potencia mayor al error promedio absoluto de la predicción sobre el valor real, y además porque el tiempo que demora en tomar efecto la medida T+4 es alrededor de 3 a 4 minutos.

El sistema dinámico de Metro S.A. posee variaciones importantes de demanda de potencia eléctrica a lo largo de su operación. Esto debido a que la cantidad de trenes existentes en el sistema no es menor, y no existe un sincronismo perfecto en la operación de los trenes que indique tener un consumo fácilmente predecible. Por esta razón, es que se hace necesario estudiar el sistema en intervalos de tiempo más cortos, los cuales permitan seguir las variaciones de potencia de forma más eficiente. A continuación se estudiará la misma red neuronal anterior, sin embargo los datos de entrenamiento serán tomados cada 5 minutos, en vez de 15 minutos, y desde las 16:00 hrs en adelante. La arquitectura de la red y los resultados de las predicciones para este nuevo caso, se muestran a continuación.




Ilustración 54 – Arquitectura de la red neuronal.




Ilustración 55 – Resultados de las predicciones. Datos cada 5 minutos para el entrenamiento

Claramente se puede apreciar una excelente respuesta por parte de las redes neuronales en la predicción de la demanda de potencia eléctrica del CDC-VV a las 18:30 hrs, cuando se realizan muestreos con una frecuencia mayor, esta vez cada 5 minutos. Cabe destacar que para esta ocasión no fue necesario incluir tantos retardos en el entrenamiento de la red. Si bien, para las predicciones cada 5 minutos se incluían retardos desde las 14:00 hrs, esta vez fue necesario incluir retardos desde las 16:00 hrs solamente. Además, la red tuvo una excelente respuesta incluso con el peak negativo como dato de entrenamiento. Los errores absolutos y porcentuales se pueden ver a continuación.




Ilustración 56 – (Izq.) Error absoluto de la predicción - (Der.) Error porcentual de las predicciones.

De la Ilustración 56 se extrae valiosa información relativa a los errores cometidos por la red neuronal al momento de la predicción. Se tuvo un error promedio absoluto alrededor de los 250 [kW], los que corresponden aproximadamente a un 1,7% de error respecto del valor real de la potencia en el CDC-VV a las 18:30 hrs.




Ilustración 57 – (Izq.) Error porcentual vs T+4 en 1 vía. - (Der.) Error porcentual vs T+4 en 2 vías.

Además los errores porcentuales vs T+4 en 1 vía y en 2 vías fueron menores a un 50%, lo que indica una certeza en las predicciones.

Se pudo ver que los resultados para las redes neuronales alimentadas con datos cada 5 minutos fueron mucho mejores que las soluciones para las redes alimentadas cada 15 minutos. Esto se tuvo incluso tomando en cuenta el dato con la aleatoriedad en el conjunto de entrenamiento. A continuación se verá el caso sin este dato aleatorio.




Ilustración 58 – Resultados de las predicciones. Datos cada 5 minutos para el entrenamiento

Como era de esperarse, las predicciones son excelentes. En la Ilustración 58 se aprecia claramente el seguimiento de las redes neuronales a la demanda de potencia eléctrica del CDC-VV. Si los cálculos no fallan, se debiese tener excelentes resultados para los errores absolutos y porcentuales.




Ilustración 59 – (Izq.) Error absoluto de la predicción - (Der.) Error porcentual de las predicciones.

El error absoluto es cercano a los 240 [kW] de potencia, con un porcentaje cercano al 1,5 % sobre el valor real de potencia demandada por el CDC-VV a las 18:30 hrs, lo que implica que se tendrán valores menores al 50% de error sobre las medidas T+4 en 1 y 2 vías en el CDC.




Ilustración 60 – (Izq.) Error porcentual vs T+4 en 1 vía. - (Der.) Error porcentual vs T+4 en 2 vías.

Recapitulando, se pudo apreciar que mientras mayor sea el seguimiento de la variable eléctrica demanda de potencia, es decir con intervalos de tiempo más pequeños, mejor serán las predicciones. Además, para intervalos pequeños, por ejemplo de 5 minutos, no se necesitará la inclusión de tantos retardos en el entrenamiento de las redes, con datos desde las 16:00 hrs basta para obtener predicciones aceptables.

Los errores porcentuales son una buena señal del comportamiento de las redes neuronales a la hora de predecir la demanda de potencia eléctrica del sistema dinámico estudiado, y la inclusión de las variables de solución T+4 en 1 y 2 vías permiten ver el desempeño de las redes en la realidad, en horario punta del sistema, para los meses de punta definidos por la CNE.

3.3.2.2. Subestación de Alta Tensión (SEAT), año 2010.

Para este sistema, se verán los 2 casos principales, en los cuales se tiene datos de conjuntos de entrenamiento cada 15 minutos y cada 5 minutos. En este caso, el instante de tiempo escogido para realizar la predicción fue a las 19:00 hrs.

3.3.2.2.1. Predicción a las 19:00 hrs.




Ilustración 61 – Arquitectura de la red neuronal. Datos cada 15 minutos




Ilustración 62 – Resultados de las predicciones. Datos cada 15 minutos para el entrenamiento




Ilustración 63 – (Izq.) Error absoluto de la predicción - (Der.) Error porcentual de las predicciones.




Ilustración 64 – (Izq.) Error porcentual vs T+4 en 1 vía. - (Der.) Error porcentual vs T+4 en 2 vías.




Ilustración 65 – Arquitectura de la red neuronal. Datos cada 5 minutos




Ilustración 66 – Resultados de las predicciones. Datos cada 5 minutos para el entrenamiento




Ilustración 67 – (Izq.) Error absoluto de la predicción - (Der.) Error porcentual de las predicciones.




Ilustración 68 – (Izq.) Error porcentual vs T+4 en 1 vía. - (Der.) Error porcentual vs T+4 en 2 vías.

3.3.3. Predicciones horario punta 2012

3.3.3.1. SEAT, año 2012.

A continuación, se presentará los resultados de 24 redes neuronales, las cuales predicen valores para el año actual, cada 5 minutos, obtenidas mediante un código en Matlab el cual configuró más de 150 redes neuronales para cada instante de predicción entre las 18:00 y las 20:00 hrs, y guardó los mejores resultados. Estos se muestran a continuación. El conjunto de entrenamiento pertenece al intervalo que va desde las 16:00 hrs, hasta un paso antes de la predicción.

3.3.3.1.1. Predicción a las 18:05 hrs.




Ilustración 69 – Datos de entrenamiento.

En la Ilustración 69 se muestran los datos con los cuales se entrenó a las redes neuronales que predecirán la demanda de potencia de Metro S.A. a las 18:05 hrs de un día hábil común. Se tienen 136 gráficos de distintos colores, los cuales corresponden al comportamiento dinámico del subsistema SEAT de 136 días entre Marzo y Octubre. Se puede visualizar un comportamiento similar para los 136 días, correspondiente a un crecimiento en la demanda de potencia mientras se avanza en los pasos de tiempo. Cabe destacar que los pasos de tiempo corresponden a la división del intervalo entre las 16:00 hrs y las 18:00 hrs en segmentos de 5 minutos, pues las muestras se tomaron con esa frecuencia y en ese intervalo, por lo tanto, los 25 pasos de tiempo mostrados en la ilustración corresponden a las 16:00; 16:05; 16:10;...; 17:50; 17:55; 18:00 hrs.

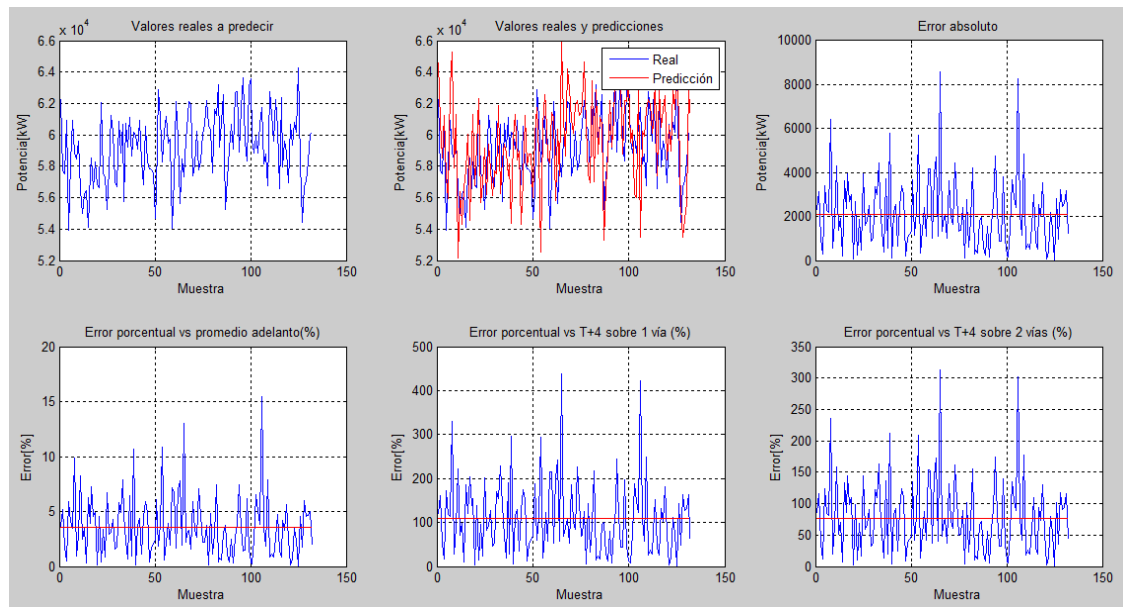


Ilustración 70 – Resultados de las predicciones.

En la Ilustración 70 se puede ver los resultados de la predicción de la demanda de potencia eléctrica del SEAT a las 18:05 hrs. Tal como se ha mostrado en los casos anteriores, seis gráficos contienen toda la información importante de la predicción.

En la esquina superior izquierda y bajo el título de “valores reales a predecir” se muestran los valores de demanda de potencia eléctrica que se tuvieron a las 18:05 hrs en los distintos días de semana y que se utilizaron para el entrenamiento de la red neuronal. Es decir, son los valores reales para las 18:05, que es exactamente lo que se quiere predecir. Se debe recordar que para redes neuronales del tipo multicapa, el entrenamiento se realiza con el algoritmo de retro-propagación, el cual realiza predicciones al azar y luego mediante sucesivas iteraciones va comparando las predicciones con los valores reales a predecir para luego modificar los pesos sinápticos y así ir reduciendo la diferencia entre las predicciones y estos valores reales.

El gráfico superior medio muestra una superposición de los valores reales recientemente descritos (en azul), con los valores predichos por la red neuronal (en rojo). Este gráfico sirve para realizar un análisis cualitativo de la predicción. Mediante la inspección de la similitud entre ambos gráficos se puede realizar una conjetura a priori si la predicción es o no aceptable.

En la esquina superior derecha se puede visualizar el error absoluto de las predicciones, calculado como la diferencia en valor absoluto entre las predicciones y los valores reales a predecir para cada día enumerado en el eje de las abscisas. Corresponde a la diferencia en potencia que se ve en la superposición de ambos gráficos.

En la esquina inferior izquierda se ilustra el error porcentual de las predicciones respecto al valor real de demanda de potencia eléctrica que se tuvo a las 18:05 en el SEAT. La línea en rojo muestra el promedio del error para todos los días de entrenamiento de la red neuronal.

El gráfico inferior medio muestra el error porcentual de las predicciones respecto al valor de potencia que correspondería si se aplicase una medida de control de velocidad T+4 sobre una vía a todas las líneas del SEAT. Es decir, es un gráfico de error porcentual en que el 100% corresponde al valor 1950 [kW], disminución de la demanda del SEAT si se aplicara T+4 en las líneas 1,2 y 5 de Metro.

Finalmente, en la esquina inferior derecha se tiene el error porcentual de las predicciones respecto a la aplicación de una medida de control de velocidad T+4 a ambas vías de las líneas 1,2,y 5 de Metro. En este caso, se tiene una disminución de 2730 [kW] si se aplica lo anterior, y es este valor el que se toma como 100% para realizar el cálculo de error porcentual de esta ilustración.

Los gráficos que seguirán a continuación, y que presentarán los resultados de las predicciones realizadas por las redes neuronales, tendrán el mismo esquema que el recién descrito, debido a que con los seis gráficos se tiene la información suficiente para realizar un análisis cualitativo y cuantitativo de las soluciones y concluir acerca de la certeza alcanzada en cada predicción.

3.3.3.1.2. Predicción a las 18:10 hrs.




Ilustración 71 – Datos de entrenamiento.

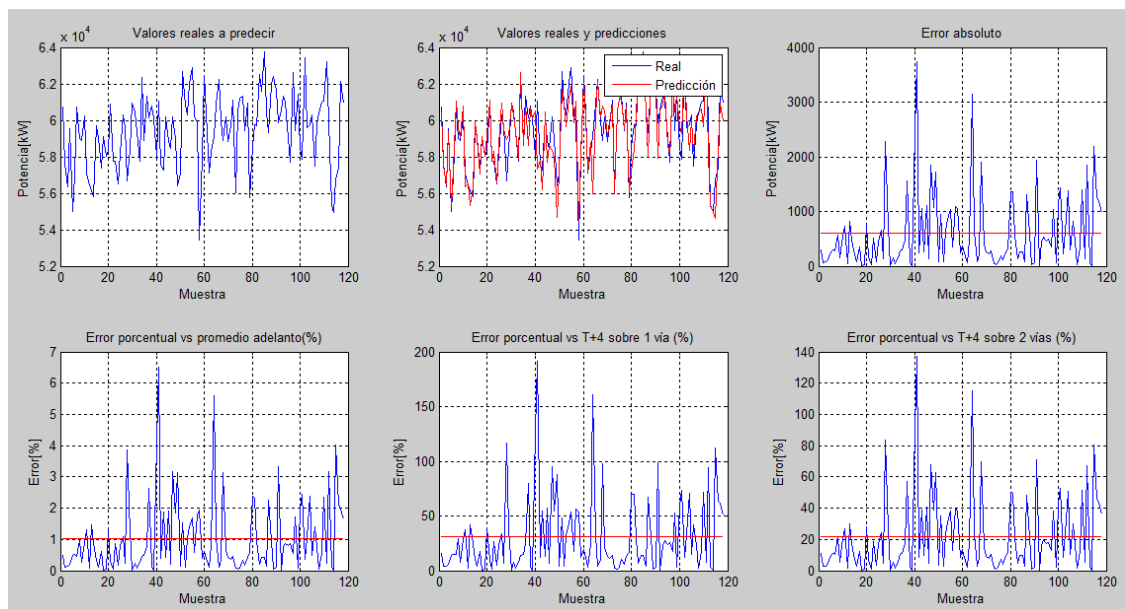


Ilustración 72 – Resultados de las predicciones.

A primera vista se puede ver la similitud entre los valores reales de demanda de potencia del SEAT a las 18:10 con las predicciones realizadas por la red neuronal. Además, se tuvo un error de aproximadamente 600 [kW] promedio que corresponden a un error porcentual de un 1% respecto del valor real, lo que hace que esta predicción sea más que acertada. Además si se visualiza el error respecto a las medidas de solución, se puede ver que en promedio una medida

T+4 en una vía de las líneas del SEAT proporcionará una disminución de demanda de potencia que será mayor al error promedio que se vio de las predicciones. Esto debido a que el error porcentual respecto de esta medida fue menor que un 40%. Asimismo para una medida T+4 en 2 vías se tuvo un error de un 20% en comparación a los efectos de aplicar esta medida a las líneas del SEAT.

3.3.3.1.3. Predicción a las 18:15 hrs.

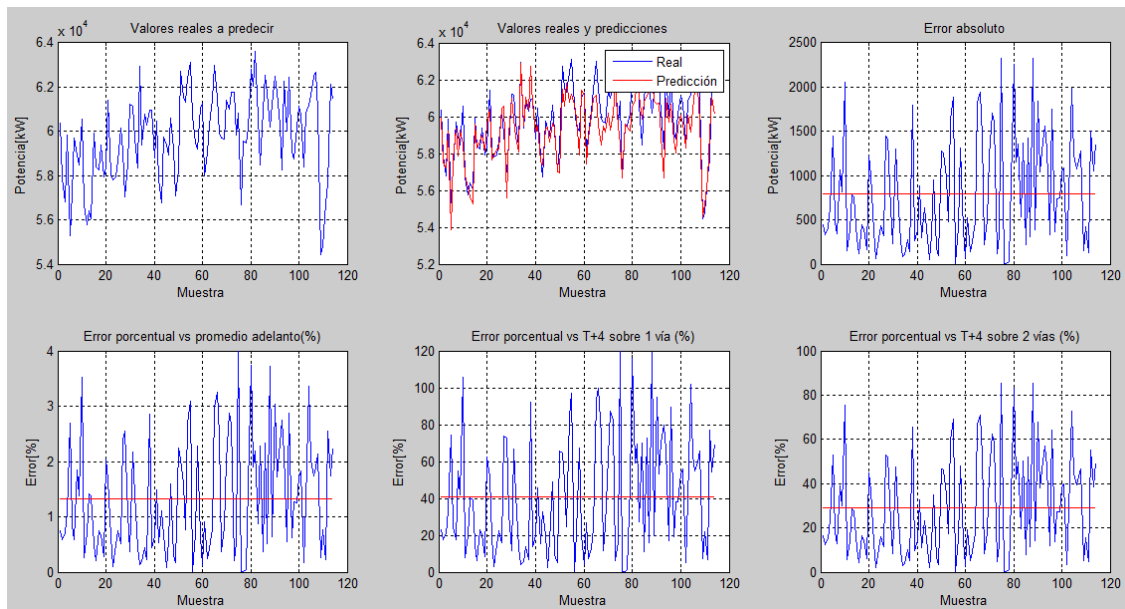


Ilustración 73 – Resultados de las predicciones.

3.3.3.1.4. Predicción a las 18:20 hrs.

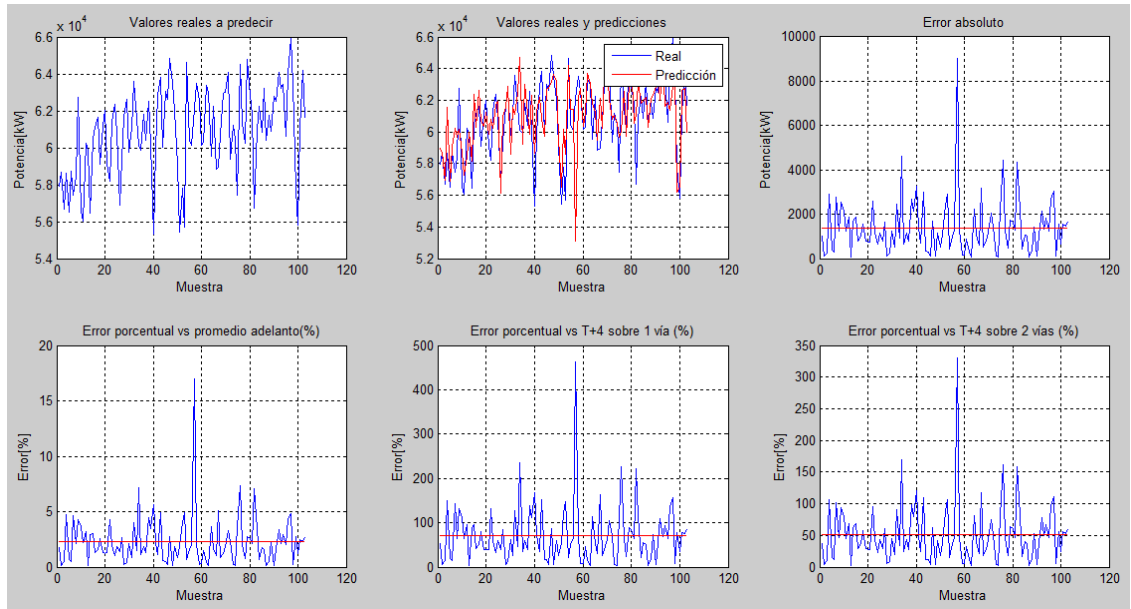


Ilustración 74 – Resultados de las predicciones.

3.3.3.1.5. Predicción a las 18:25 hrs.

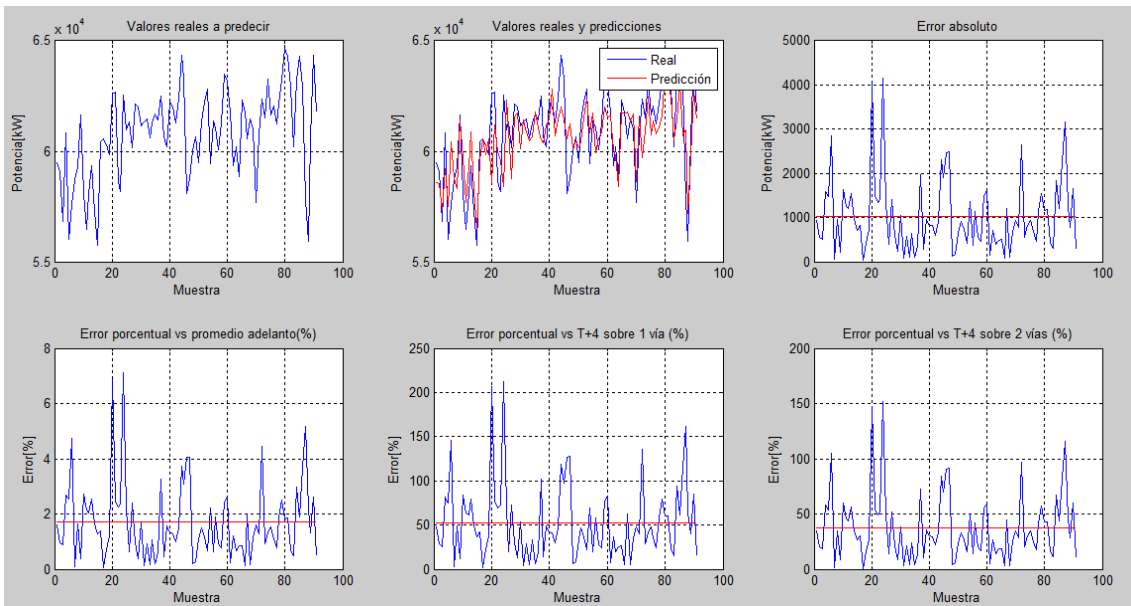


Ilustración 75 – Resultados de las predicciones.

3.3.3.1.6. Predicción a las 18:30 hrs.

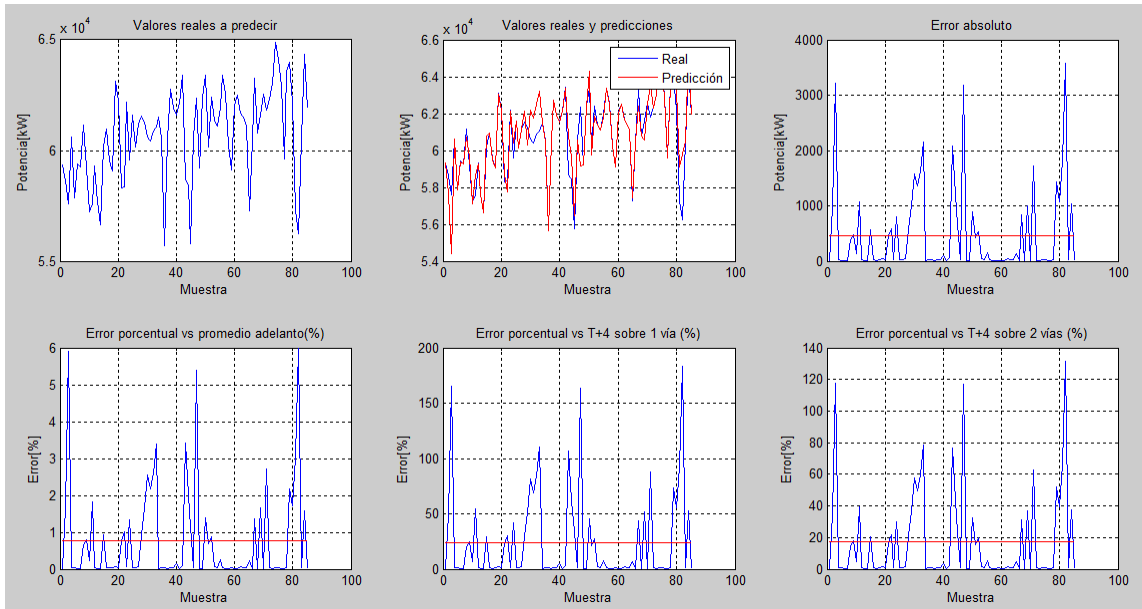


Ilustración 76 – Resultados de las predicciones.

3.3.3.1.7. Predicción a las 18:35 hrs.

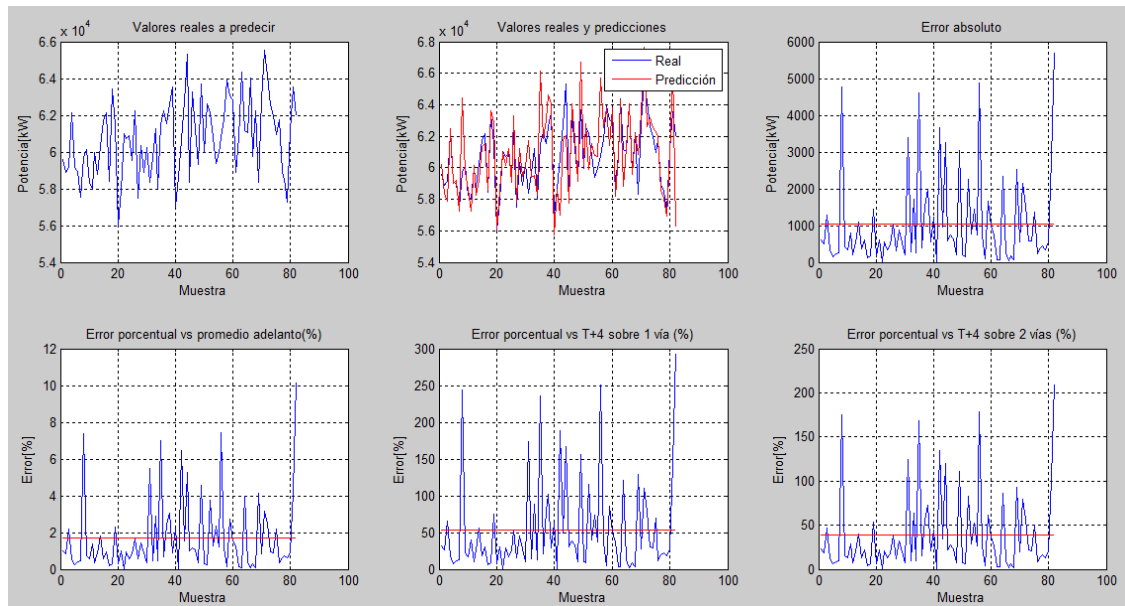


Ilustración 77 – Resultados de las predicciones.

3.3.3.1.8. Predicción a las 18:40 hrs.

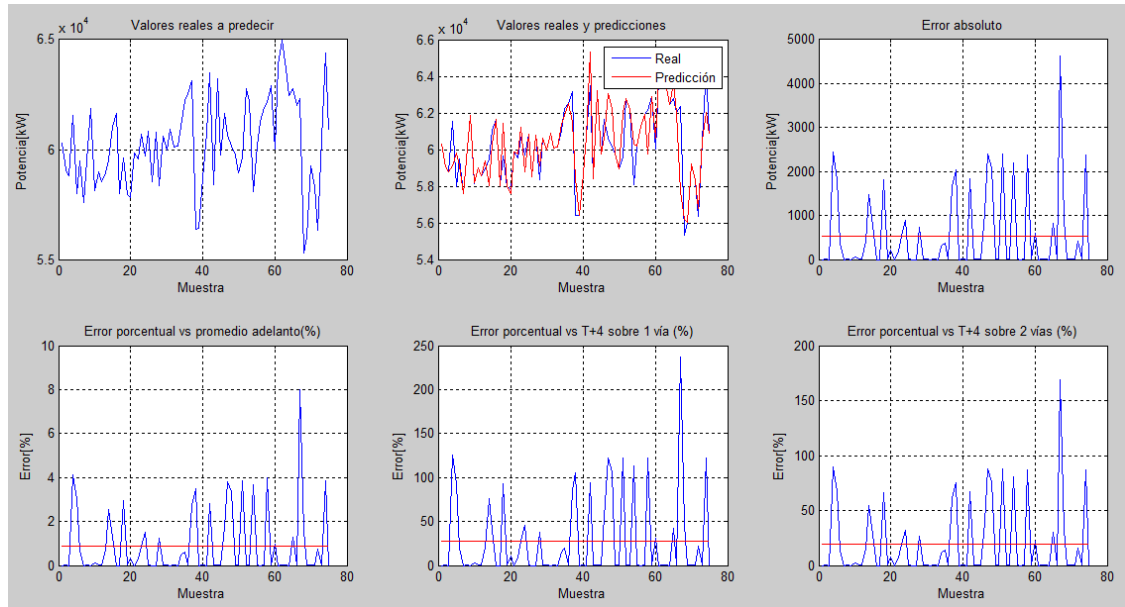


Ilustración 78 – Resultados de las predicciones.

3.3.3.1.9. Predicción a las 18:45 hrs.

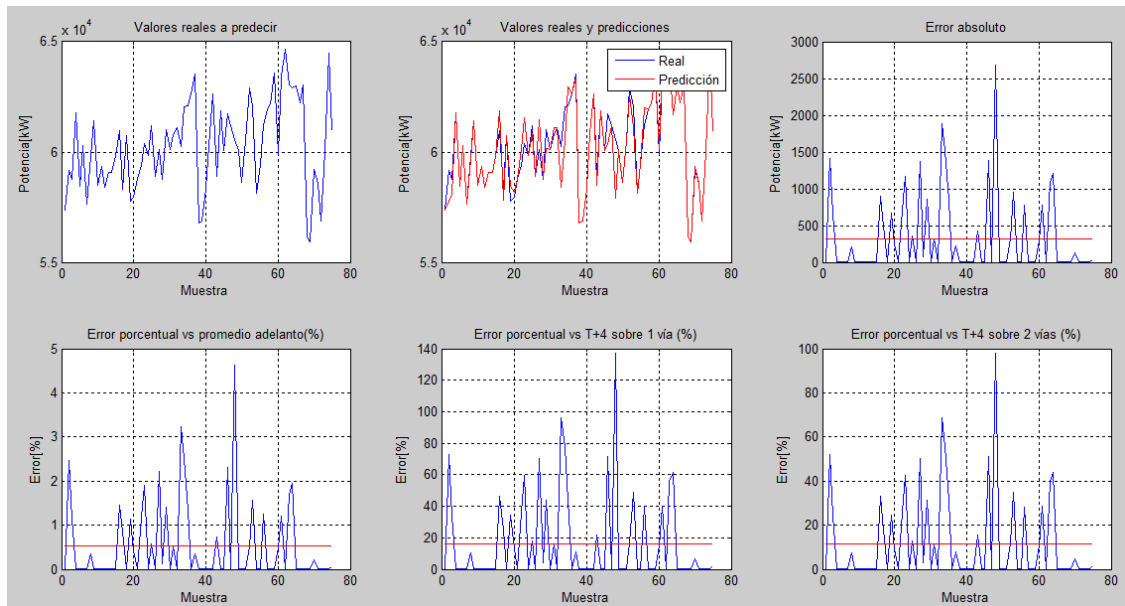


Ilustración 79 – Resultados de las predicciones.

3.3.3.1.10. Predicción a las 18:50 hrs.

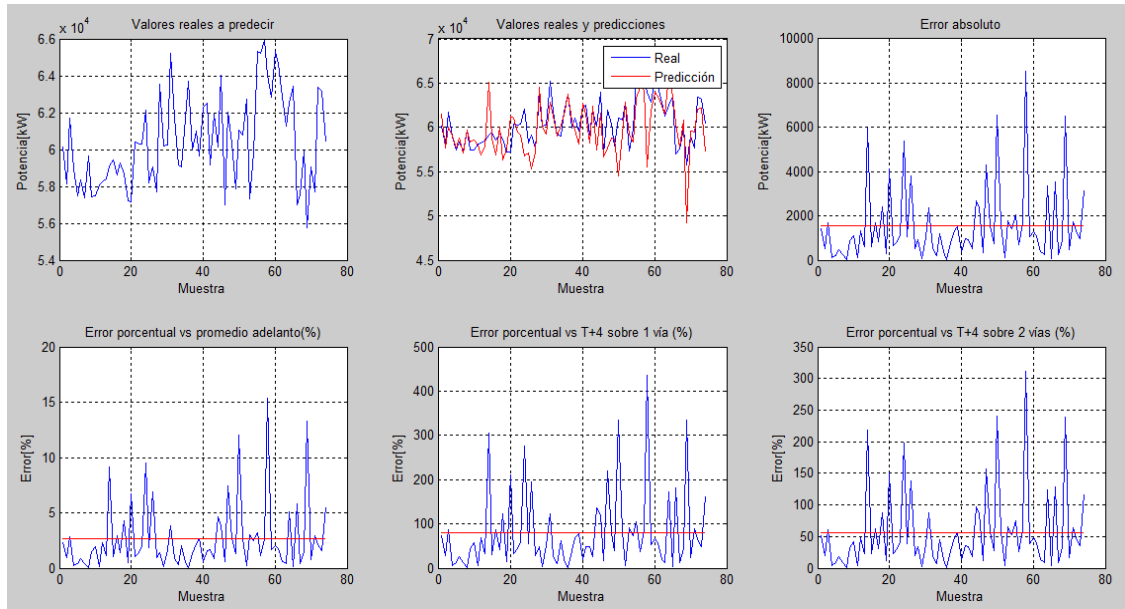


Ilustración 80 – Resultados de las predicciones.

3.3.3.1.11. Predicción a las 18:55 hrs.

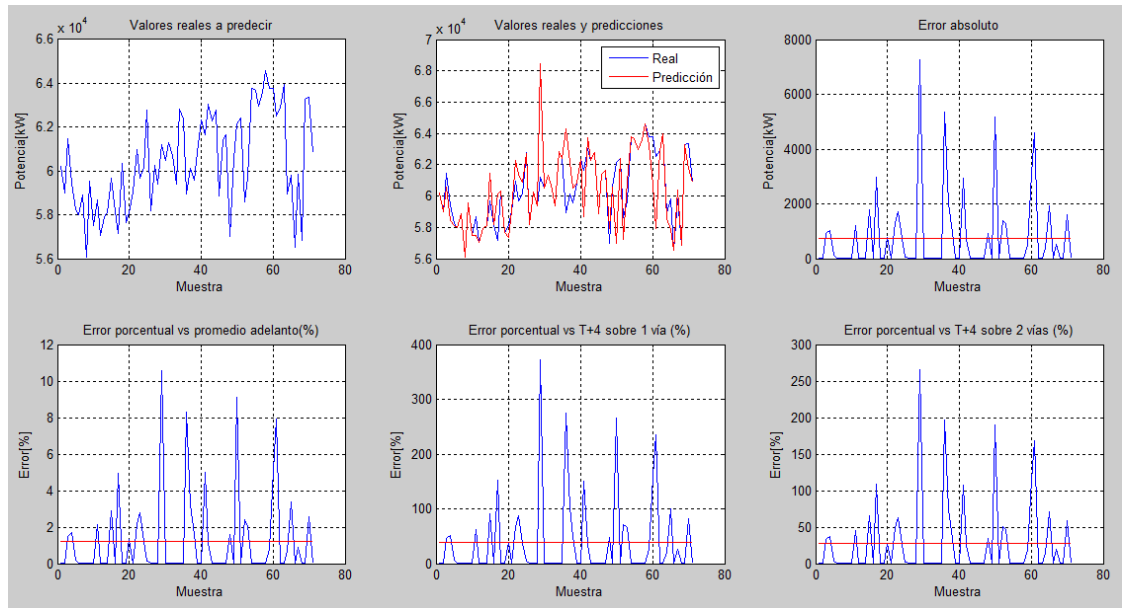


Ilustración 81 – Resultados de las predicciones.

3.3.3.1.12. Predicción a las 19:00 hrs.

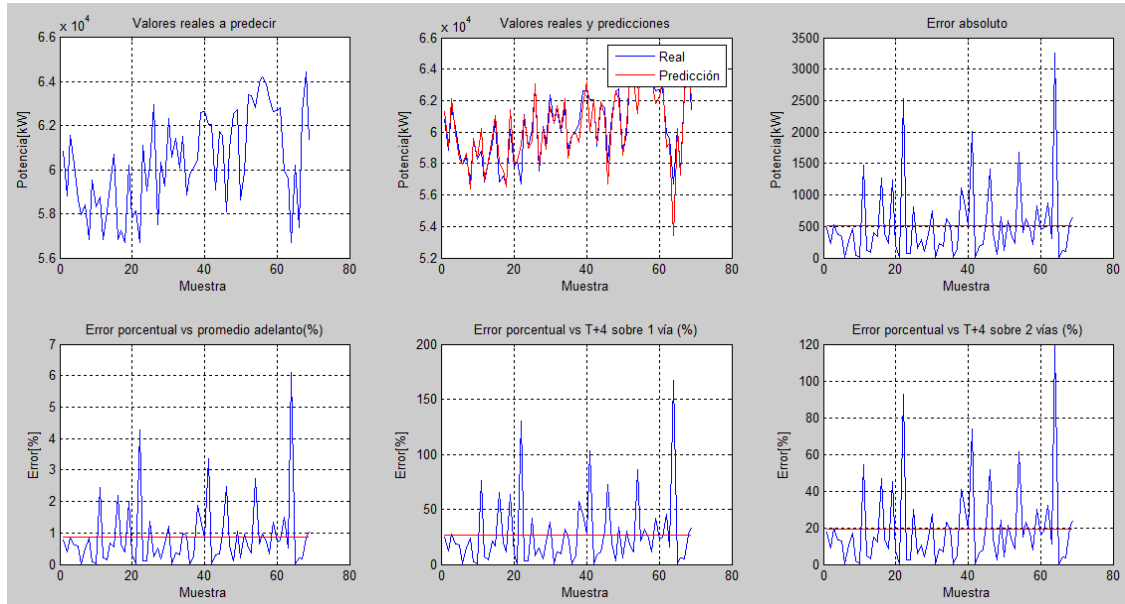


Ilustración 82 – Resultados de las predicciones.

3.3.3.1.13. Predicción a las 19:05 hrs.

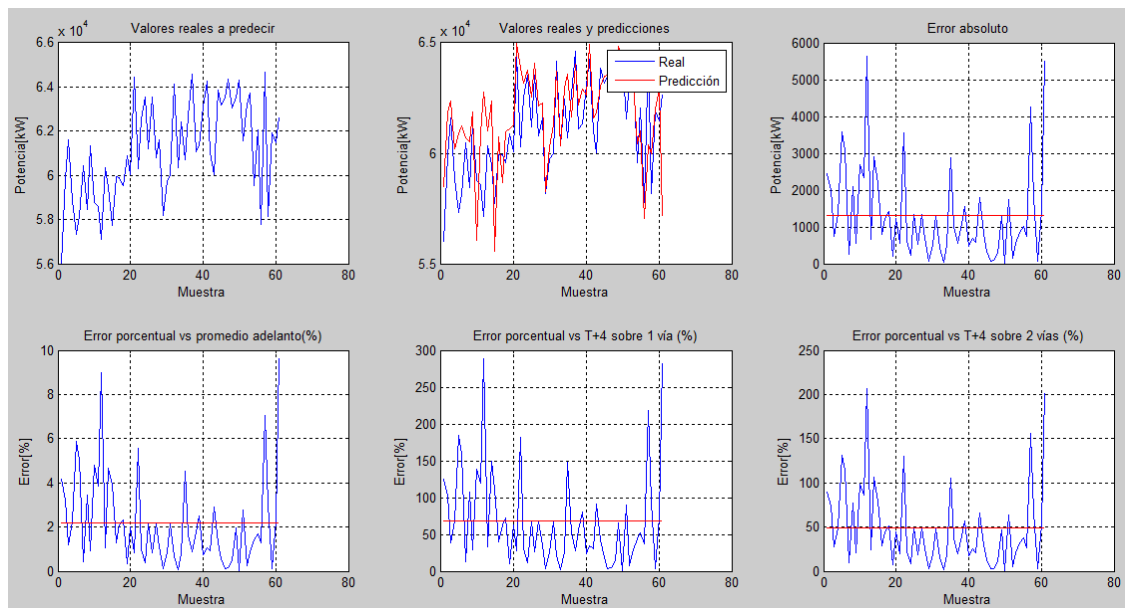


Ilustración 83 – Resultados de las predicciones.

3.3.3.1.14. Predicción a las 19:10 hrs.

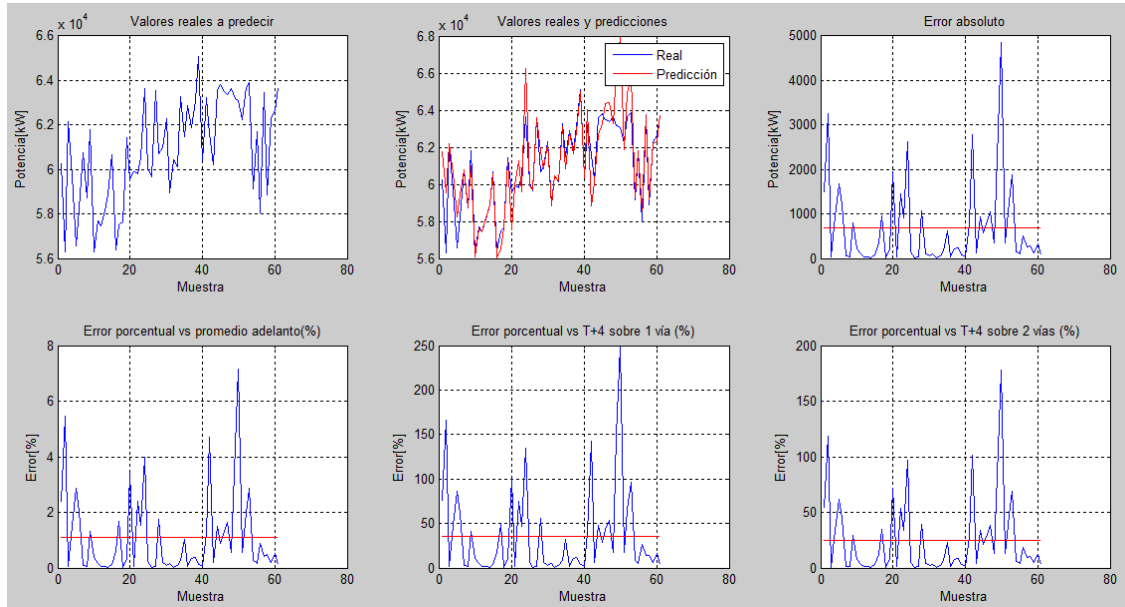


Ilustración 84 – Resultados de las predicciones.

3.3.3.1.15. Predicción a las 19:15 hrs.

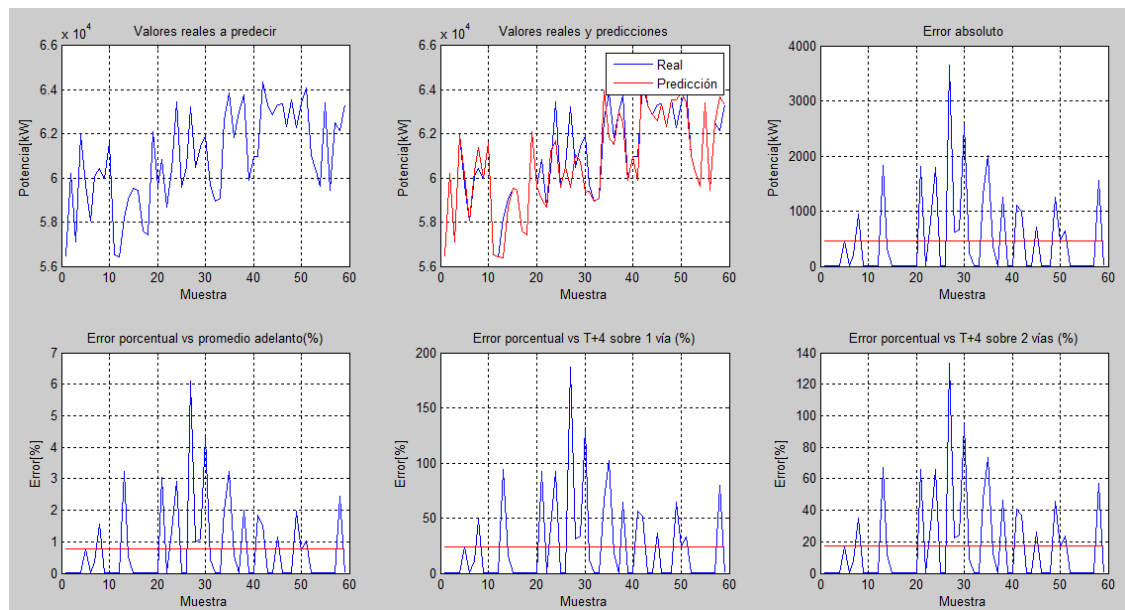


Ilustración 85 – Resultados de las predicciones.

3.3.3.1.16. Predicción a las 19:20 hrs.

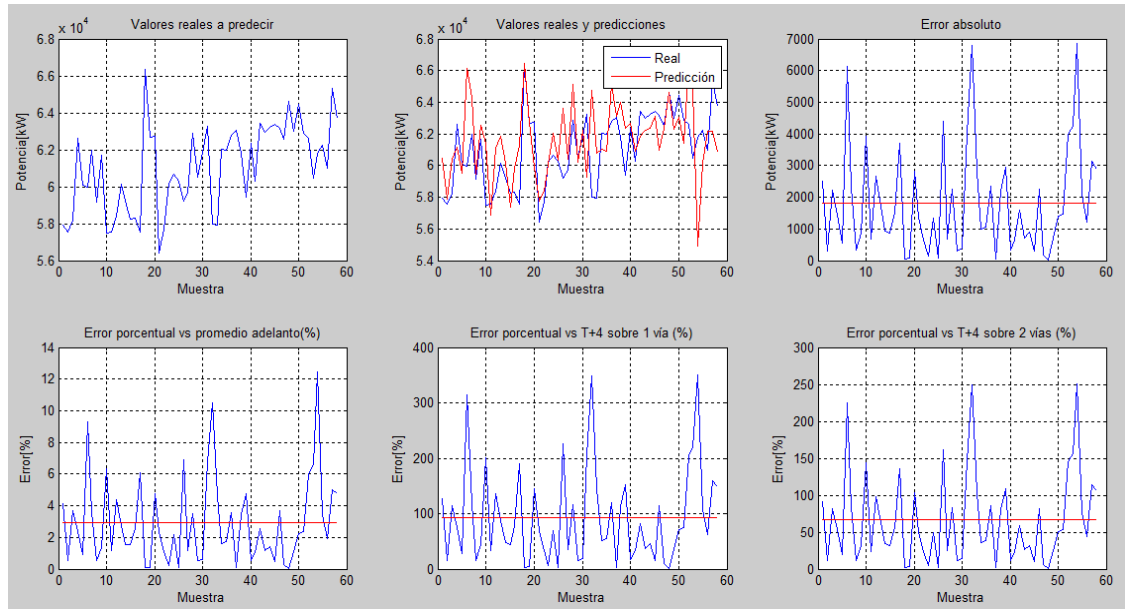


Ilustración 86 – Resultados de las predicciones.

3.3.3.1.17. Predicción a las 19:25 hrs.

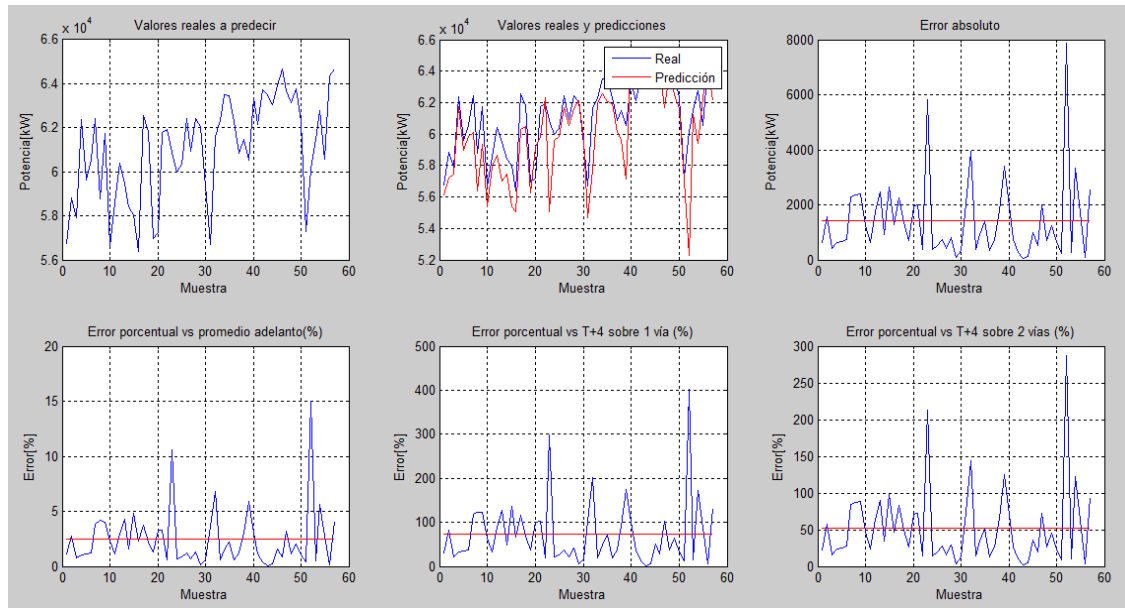


Ilustración 87 – Resultados de las predicciones.

3.3.3.1.18. Predicción a las 19:30 hrs.

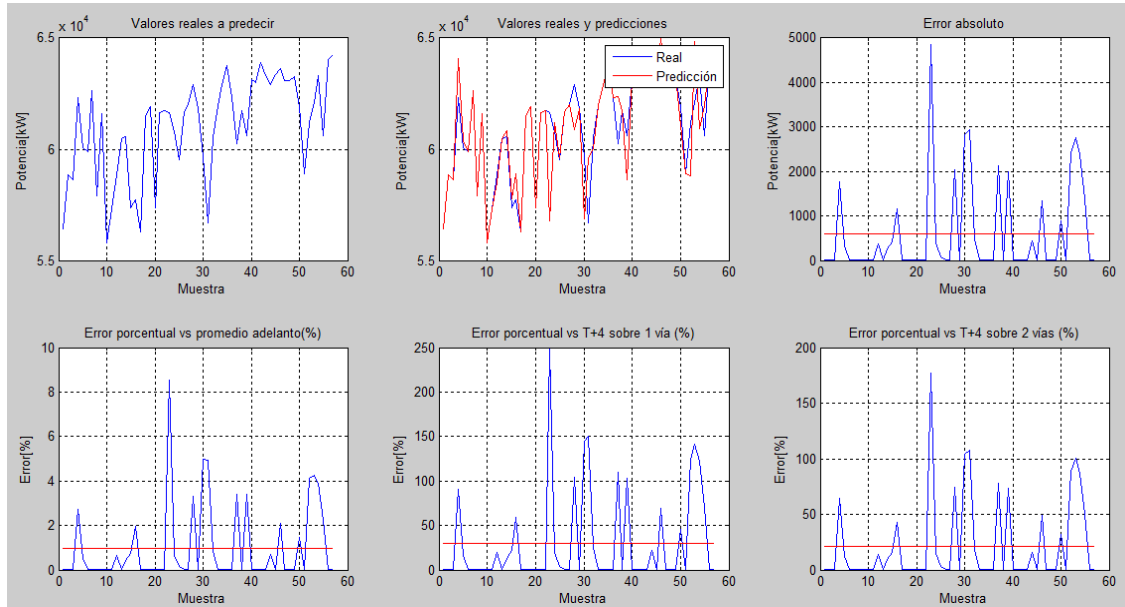


Ilustración 88 – Resultados de las predicciones.

3.3.3.1.19. Predicción a las 19:35 hrs.

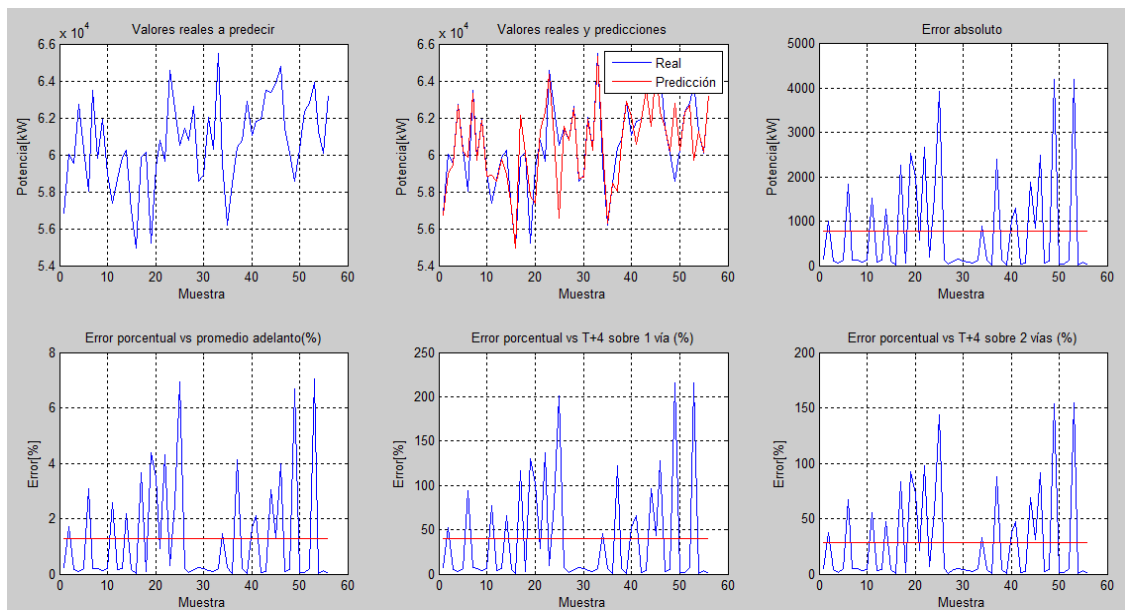


Ilustración 89 – Resultados de las predicciones.

3.3.3.1.20. Predicción a las 19:40 hrs.

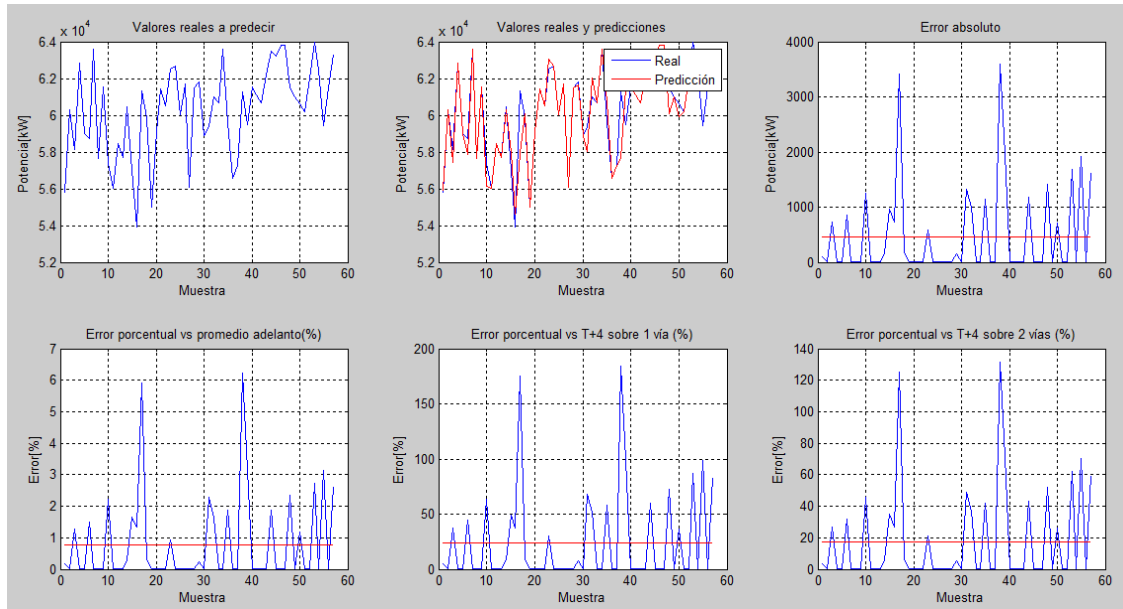


Ilustración 90 – Resultados de las predicciones.

3.3.3.1.21. Predicción a las 19:45 hrs.

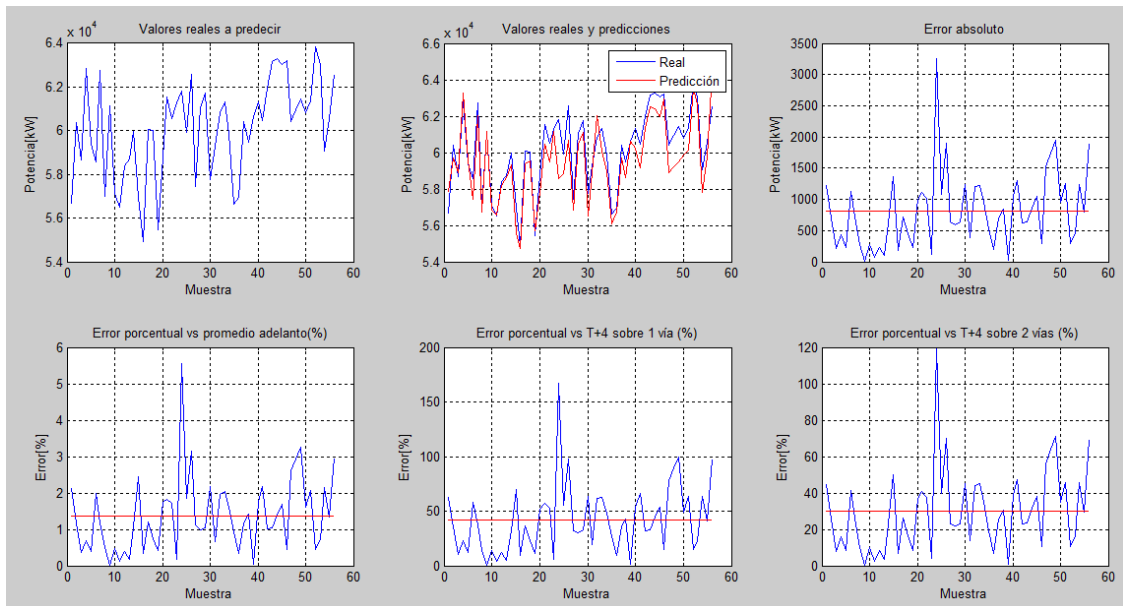


Ilustración 91 – Resultados de las predicciones.

3.3.3.1.22. Predicción a las 19:50 hrs.

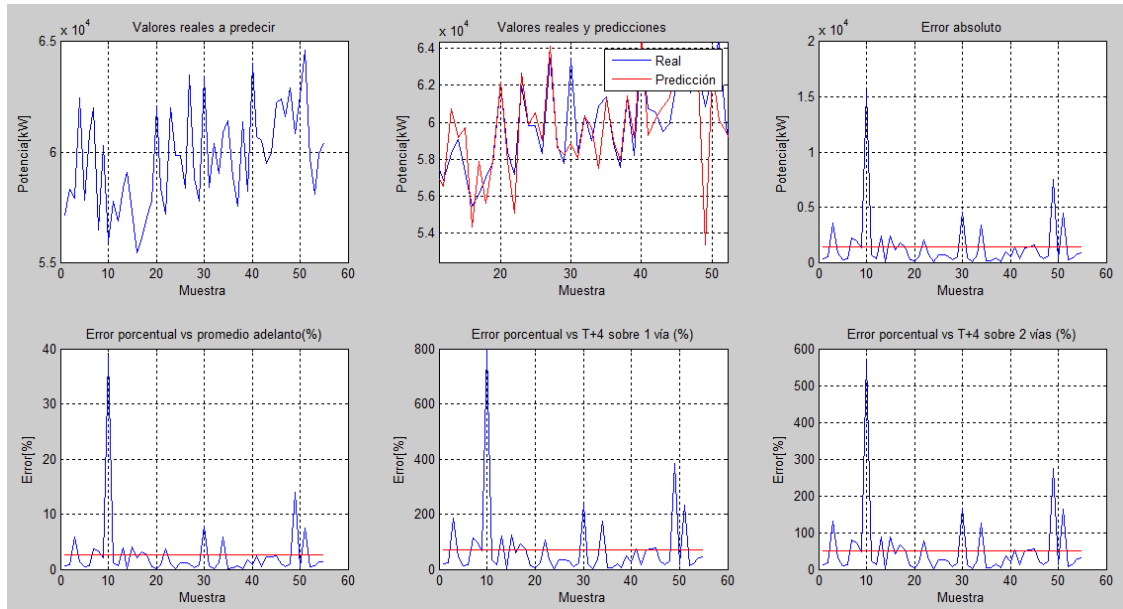


Ilustración 92 – Resultados de las predicciones.

3.3.3.1.23. Predicción a las 19:55 hrs.

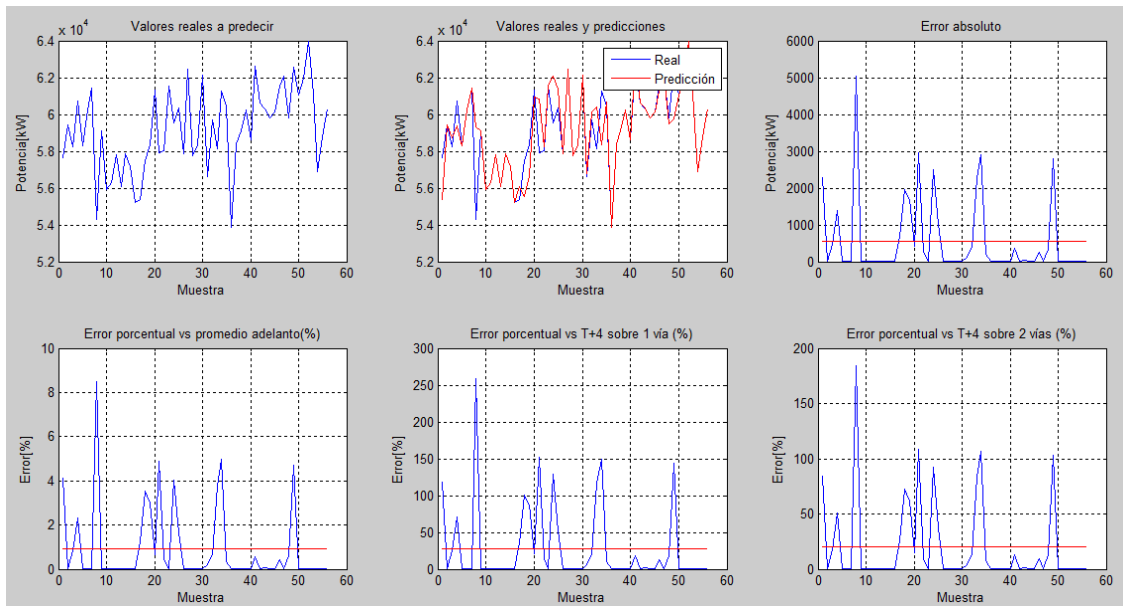


Ilustración 93 – Resultados de las predicciones.

3.3.3.1.24. Predicción a las 20:00 hrs.

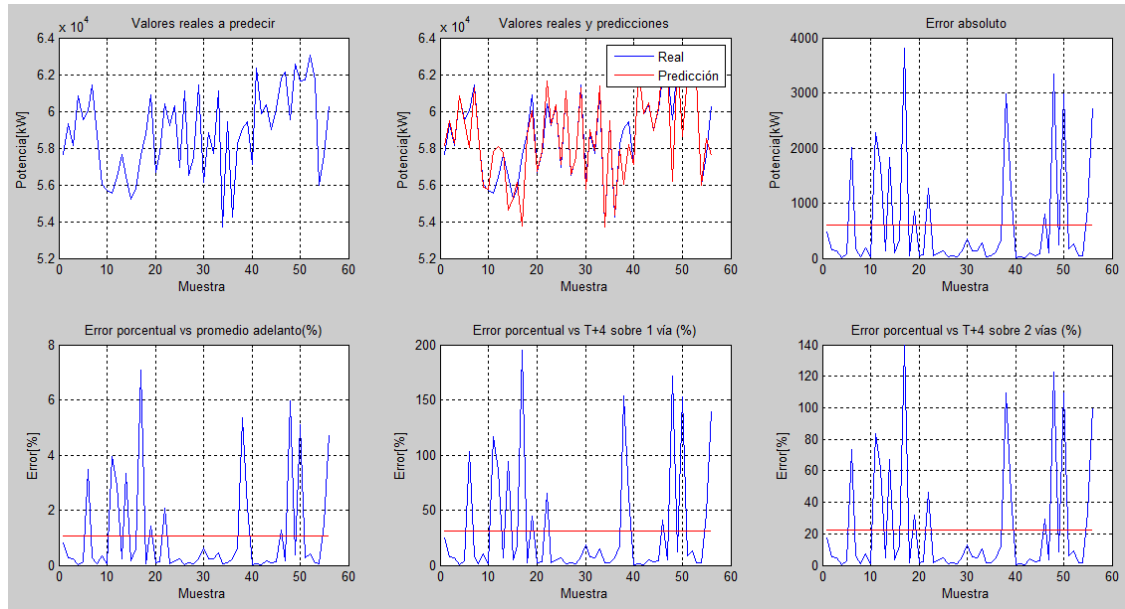


Ilustración 94 – Resultados de las predicciones.

3.3.3.2. CDC-VV, año 2012.

3.3.3.2.1. Predicción a las 18:05 hrs.

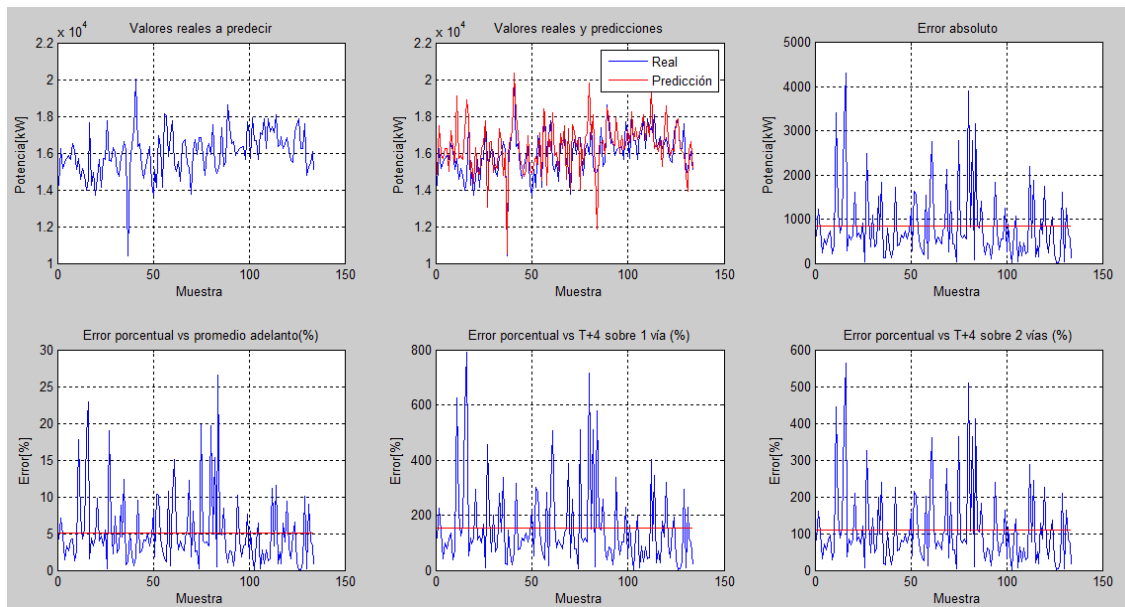


Ilustración 95 – Resultados de las predicciones.

3.3.3.2. Predicción a las 18:10 hrs.

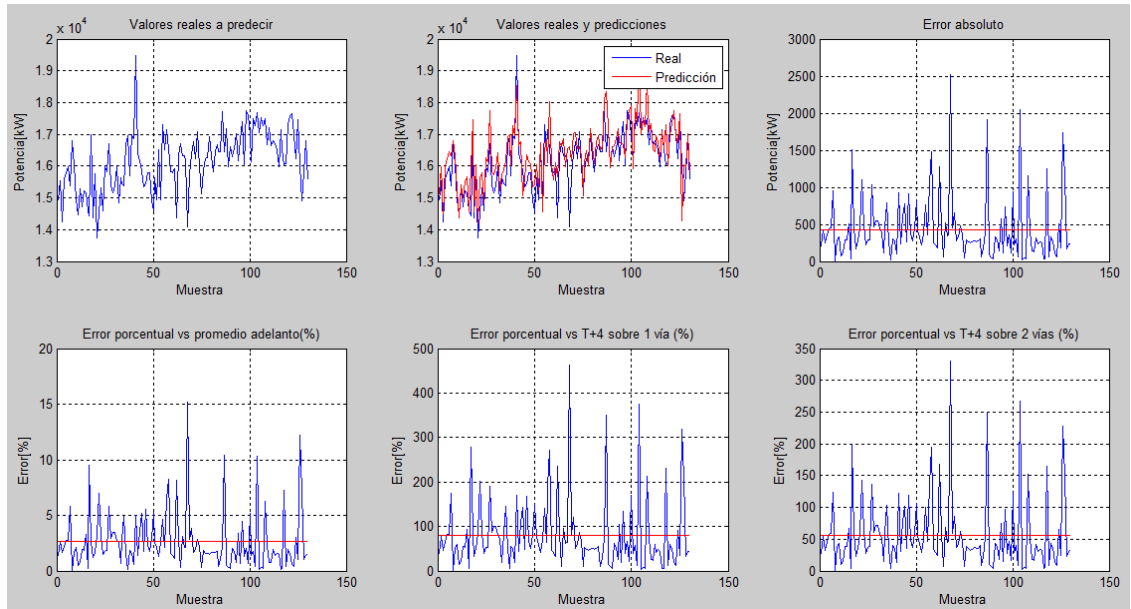


Ilustración 96 – Resultados de las predicciones.

3.3.3.3. Predicción a las 18:15 hrs.

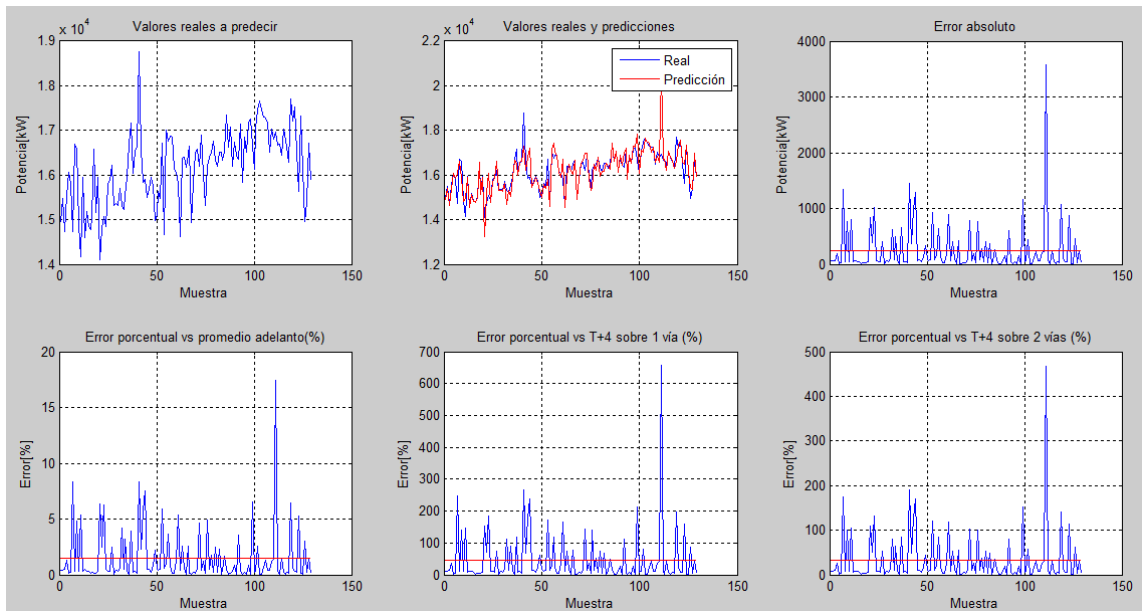


Ilustración 97 – Resultados de las predicciones.

3.3.3.2.4. Predicción a las 18:20 hrs.

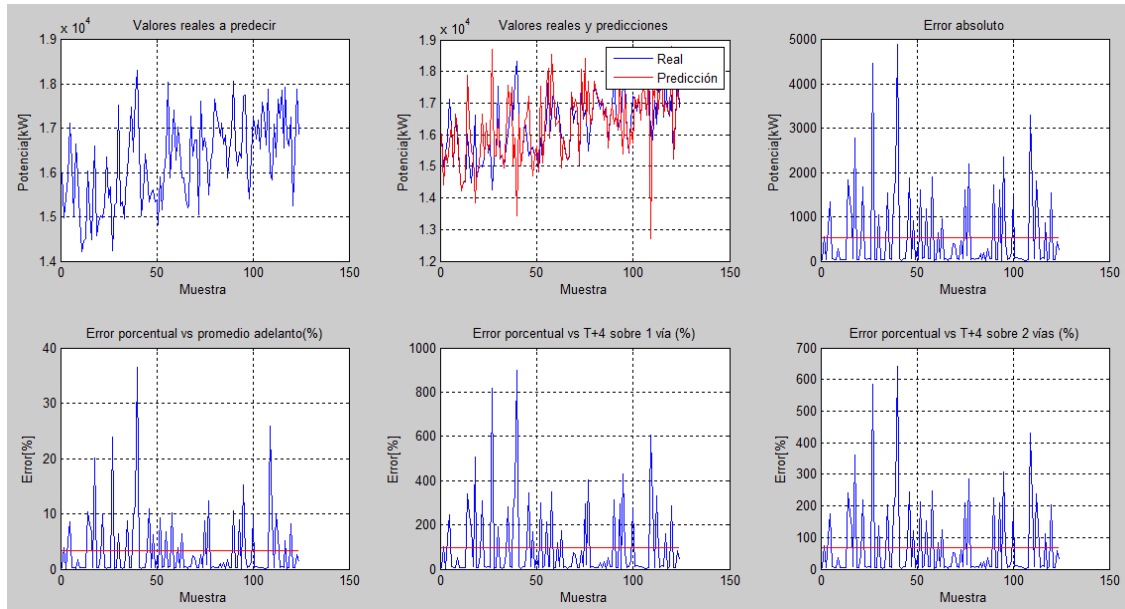


Ilustración 98 – Resultados de las predicciones.

3.3.3.2.5. Predicción a las 18:25 hrs.

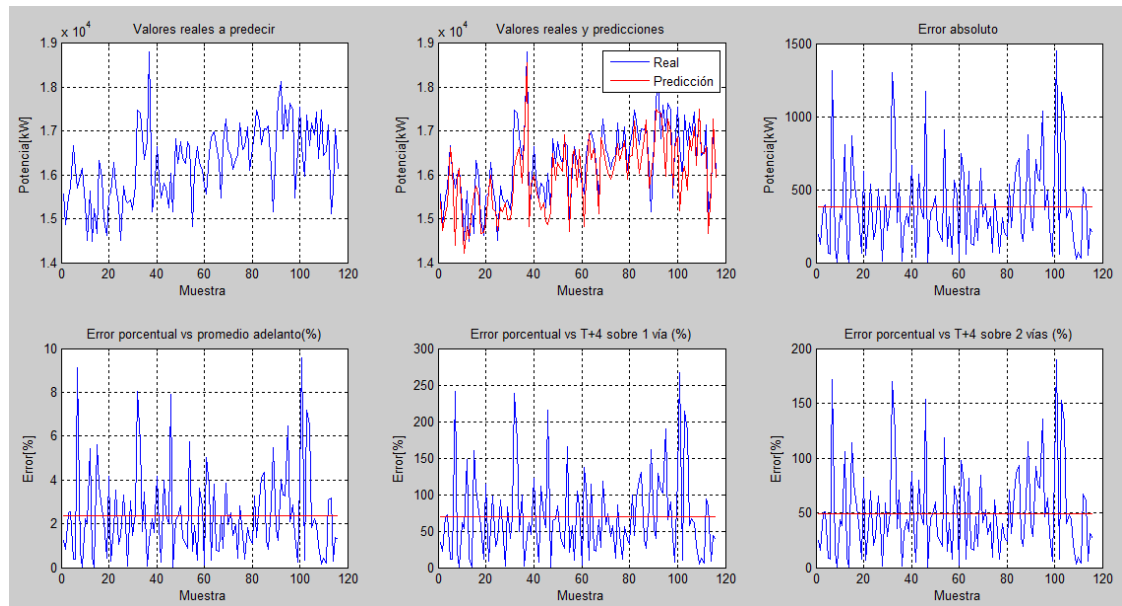


Ilustración 99 – Resultados de las predicciones.

3.3.3.2.6. Predicción a las 18:30 hrs.

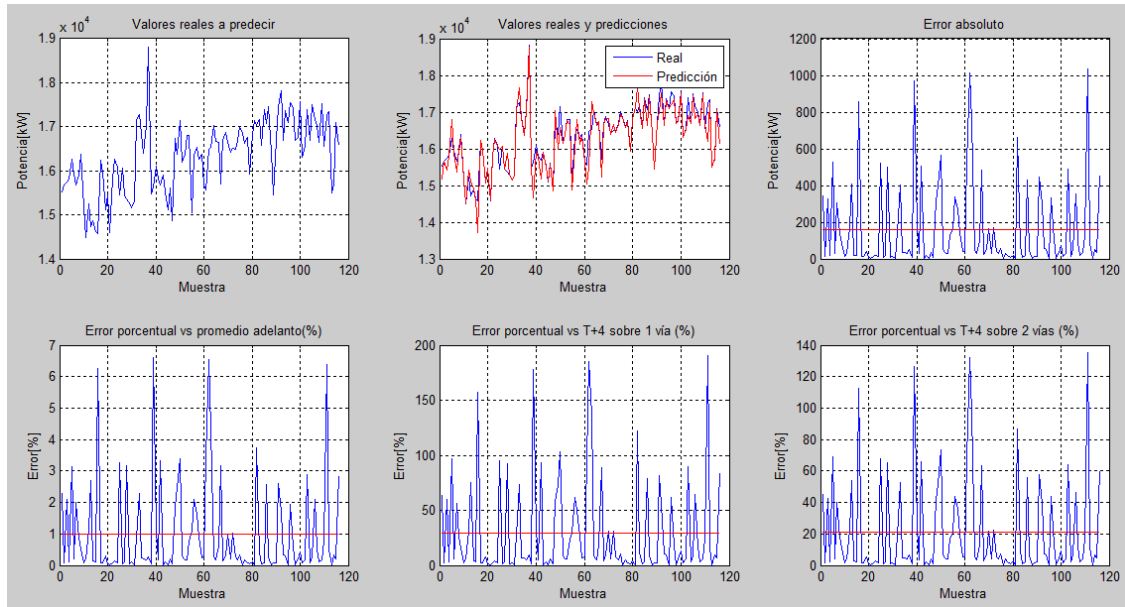


Ilustración 100 – Resultados de las predicciones.

3.3.3.2.7. Predicción a las 18:35 hrs.

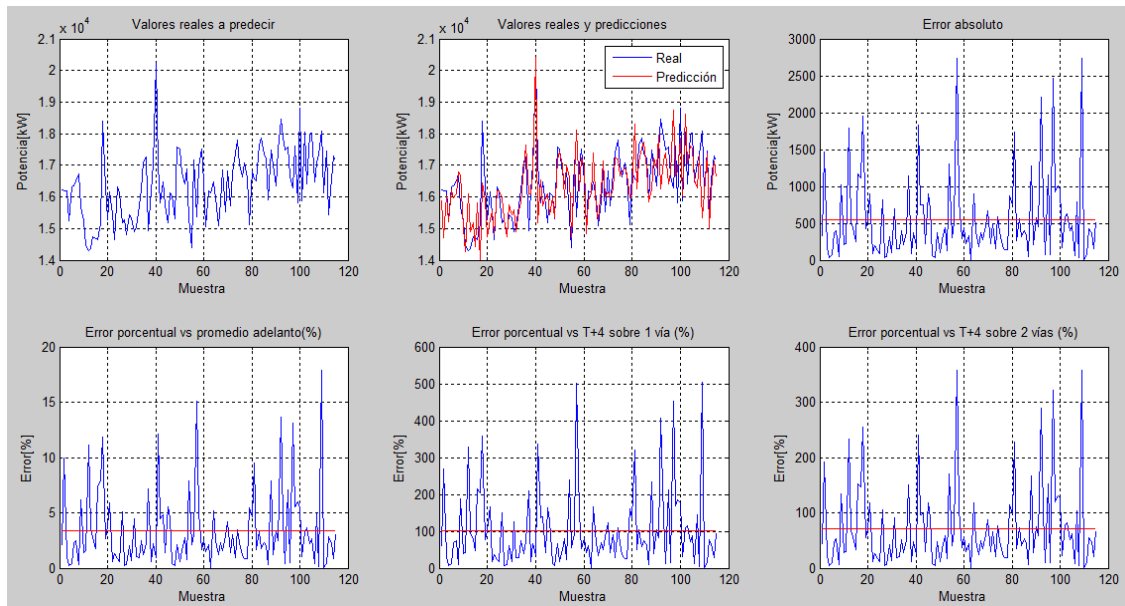


Ilustración 101 – Resultados de las predicciones.

3.3.3.2.8. Predicción a las 18:40 hrs.

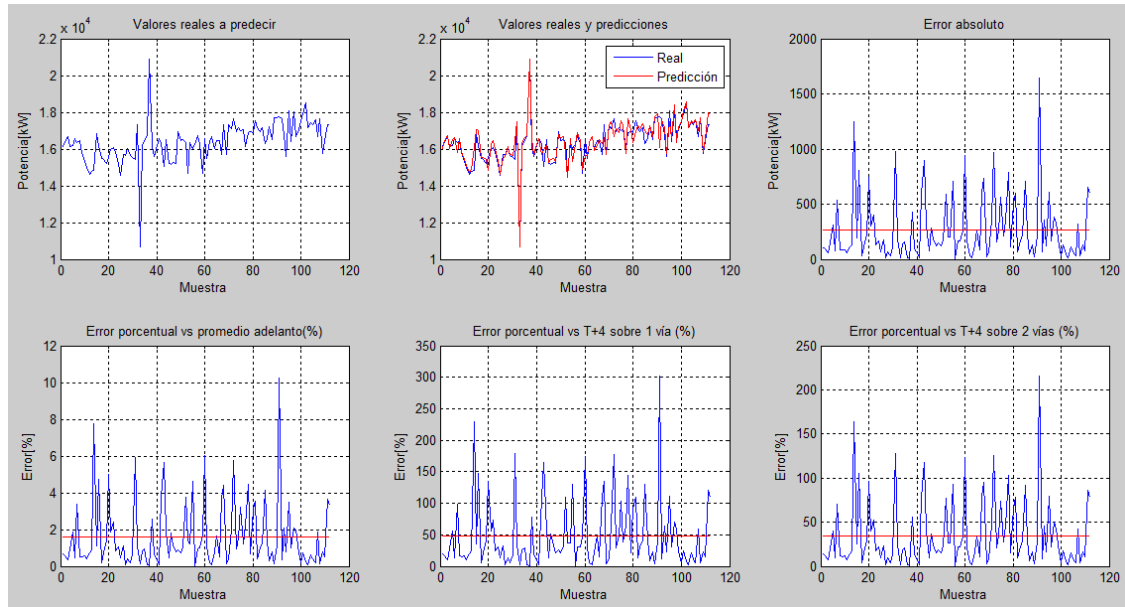


Ilustración 102 – Resultados de las predicciones.

3.3.3.2.9. Predicción a las 18:45 hrs.

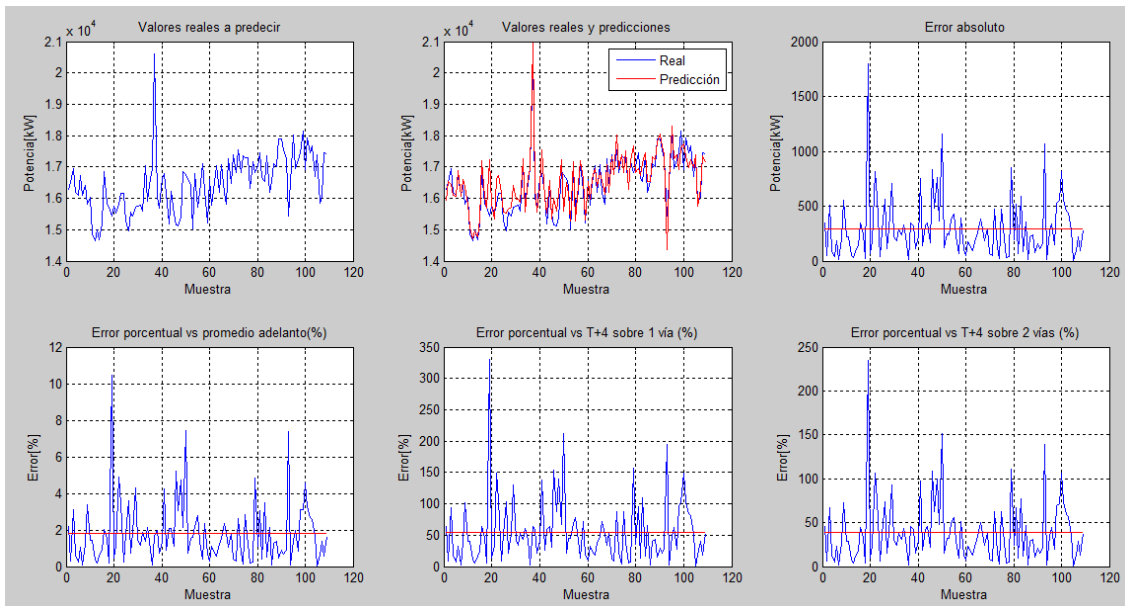


Ilustración 103 – Resultados de las predicciones.

3.3.3.2.10. Predicción a las 18:50 hrs.

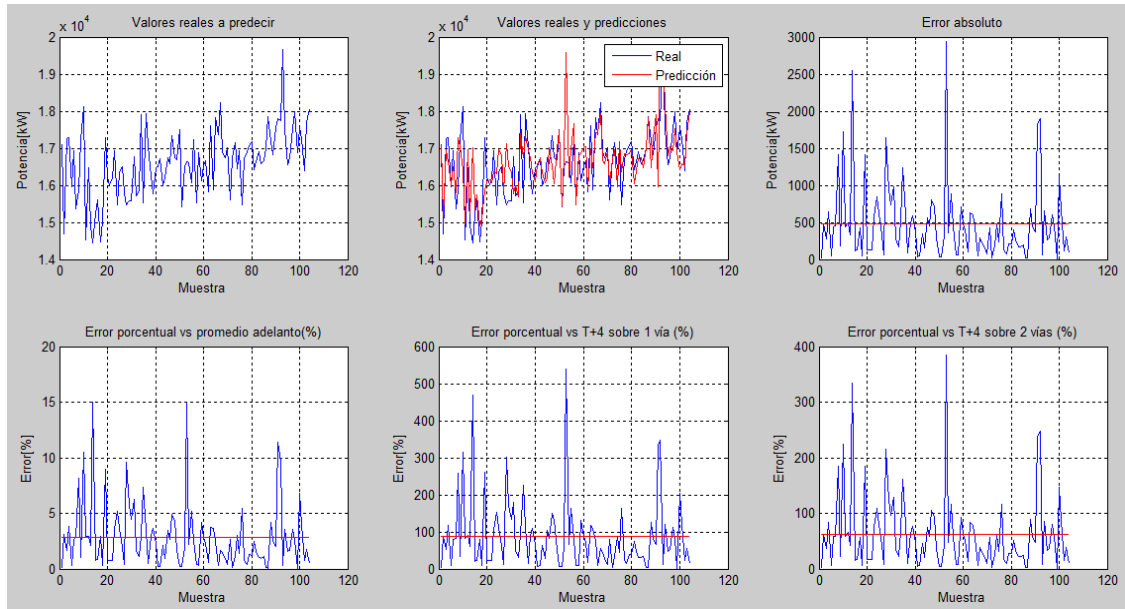


Ilustración 104 – Resultados de las predicciones.

3.3.3.2.11. Predicción a las 18:55 hrs.

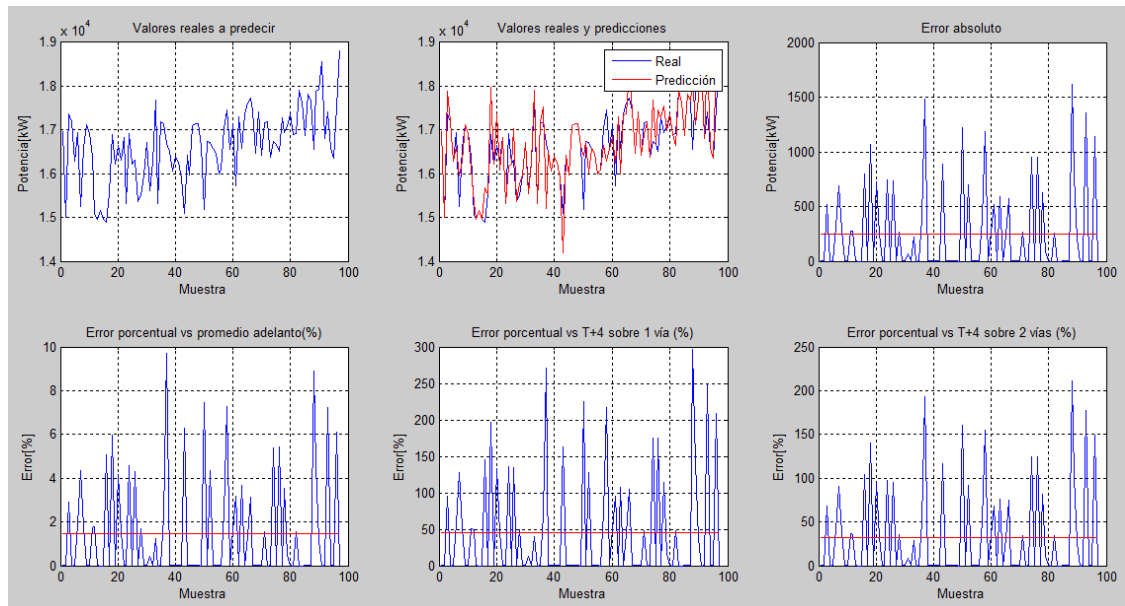


Ilustración 105 – Resultados de las predicciones.

3.3.3.2.12. Predicción a las 19:00 hrs.

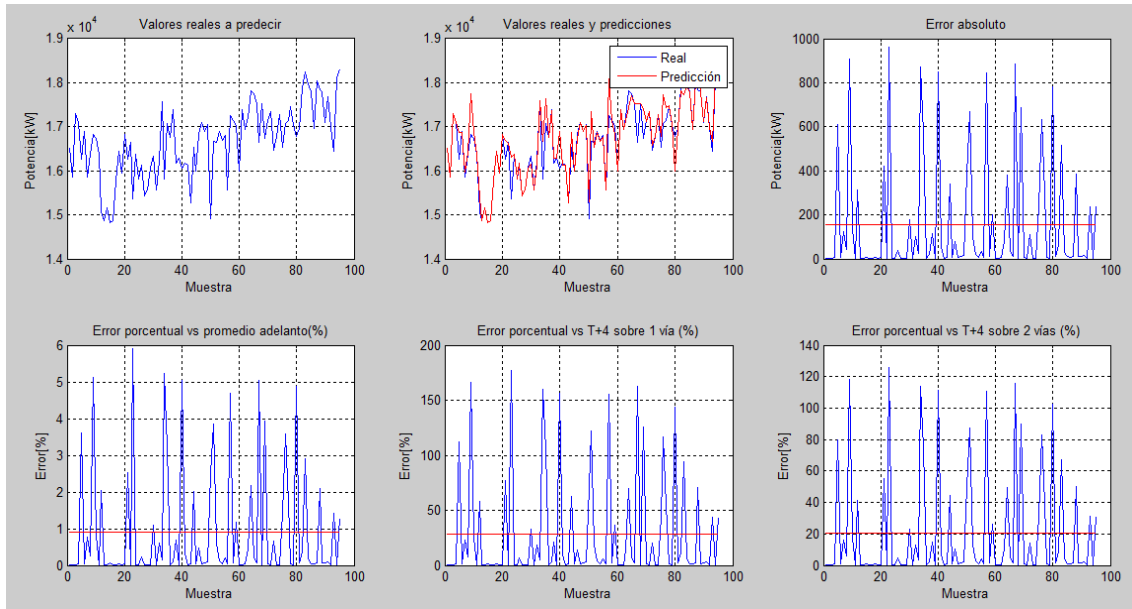


Ilustración 106 – Resultados de las predicciones.

3.3.3.2.13. Predicción a las 19:05 hrs.

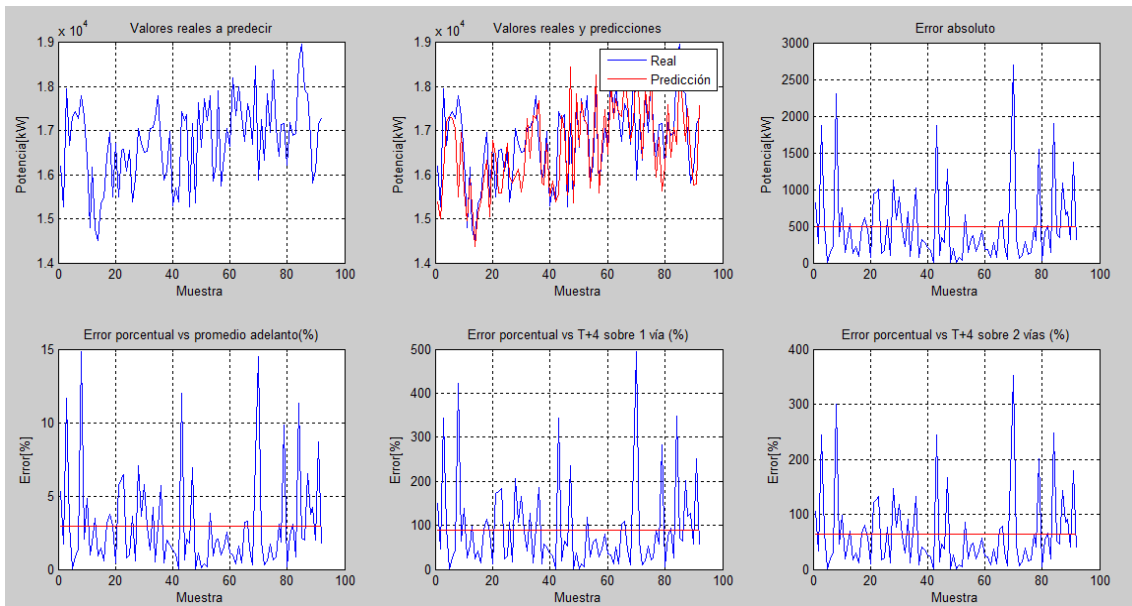


Ilustración 107 – Resultados de las predicciones.

3.3.3.2.14. Predicción a las 19:10 hrs.

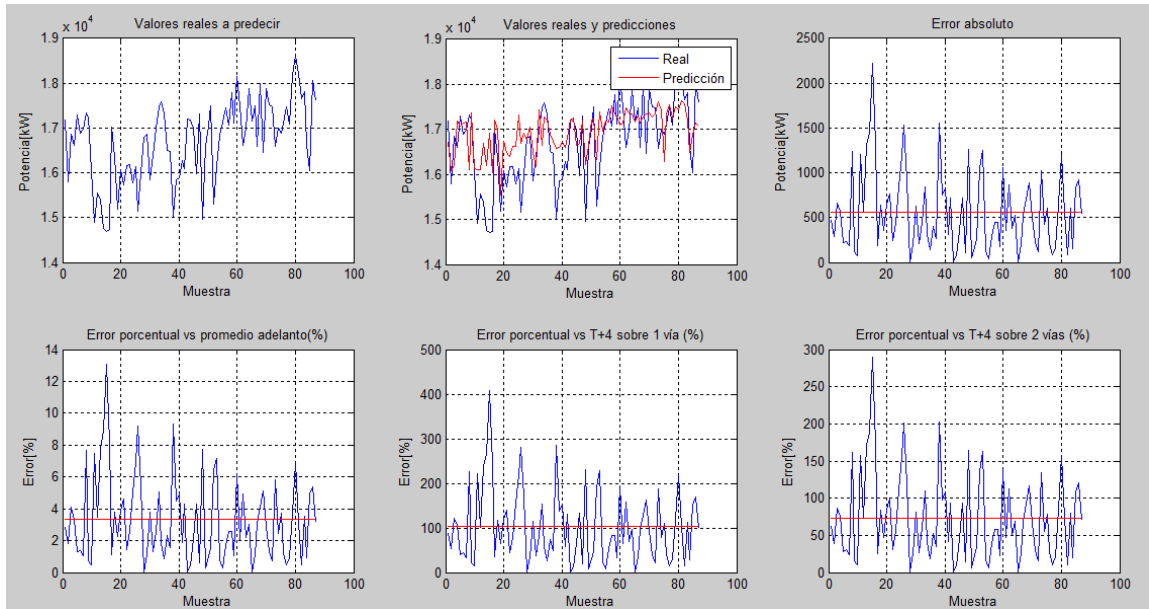


Ilustración 108 – Resultados de las predicciones.

3.3.3.2.15. Predicción a las 19:15 hrs.

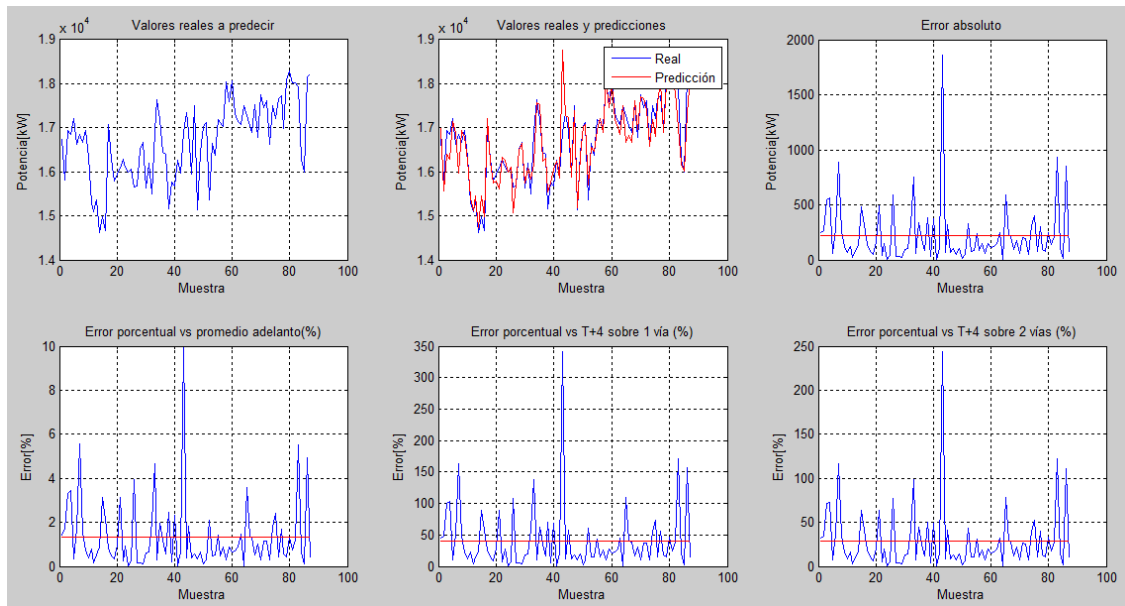


Ilustración 109 – Resultados de las predicciones.

3.3.3.2.16. Predicción a las 19:20 hrs.

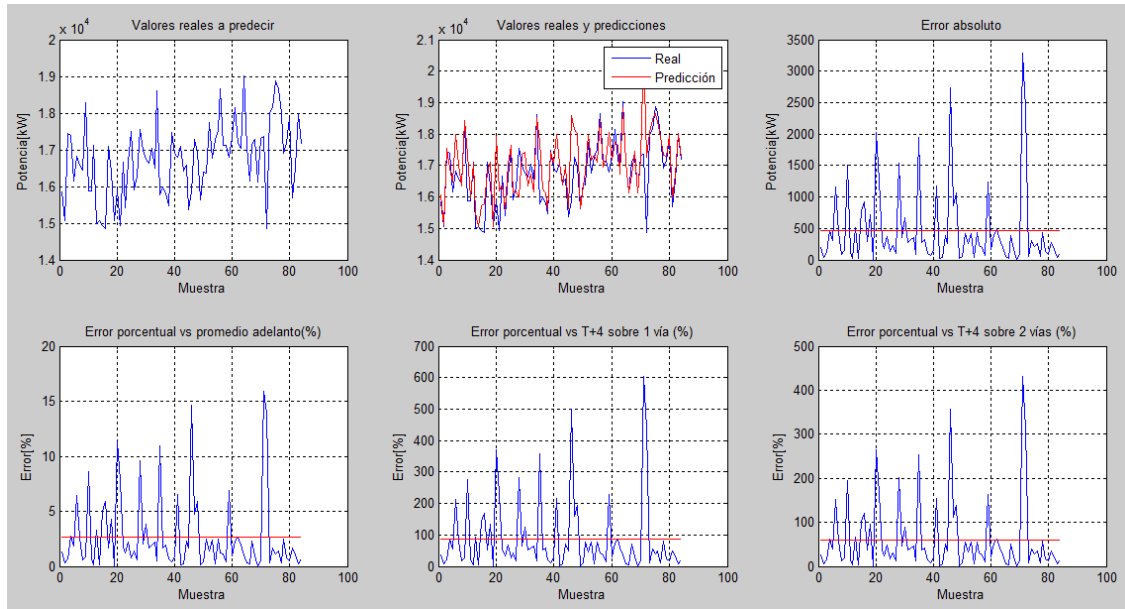


Ilustración 110 – Resultados de las predicciones.

3.3.3.2.17. Predicción a las 19:25 hrs.

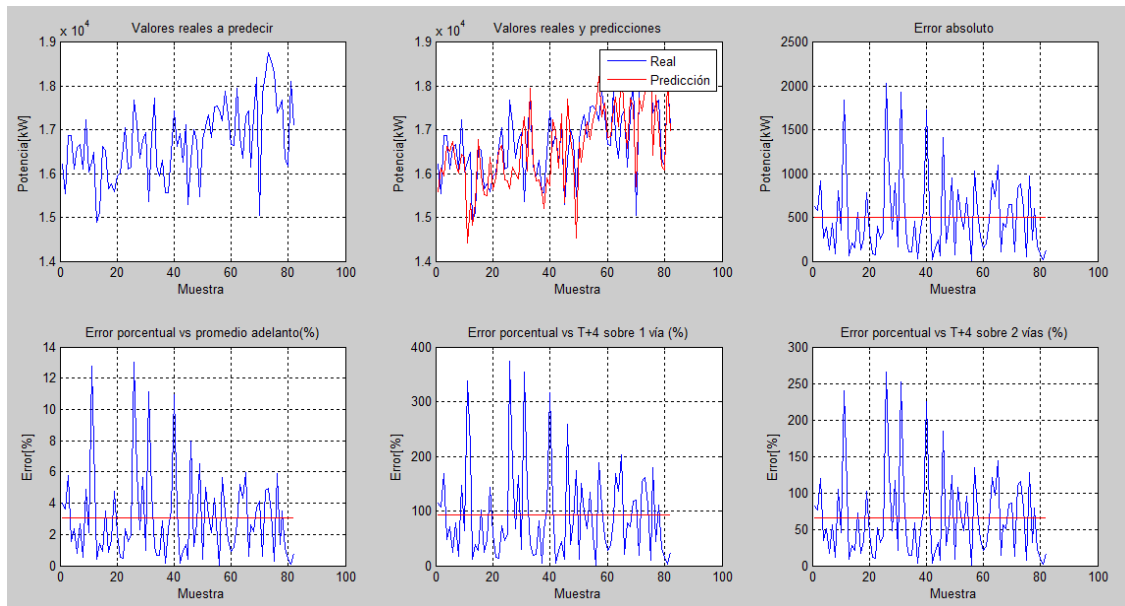


Ilustración 111 – Resultados de las predicciones.

3.3.3.2.18. Predicción a las 19:30 hrs.

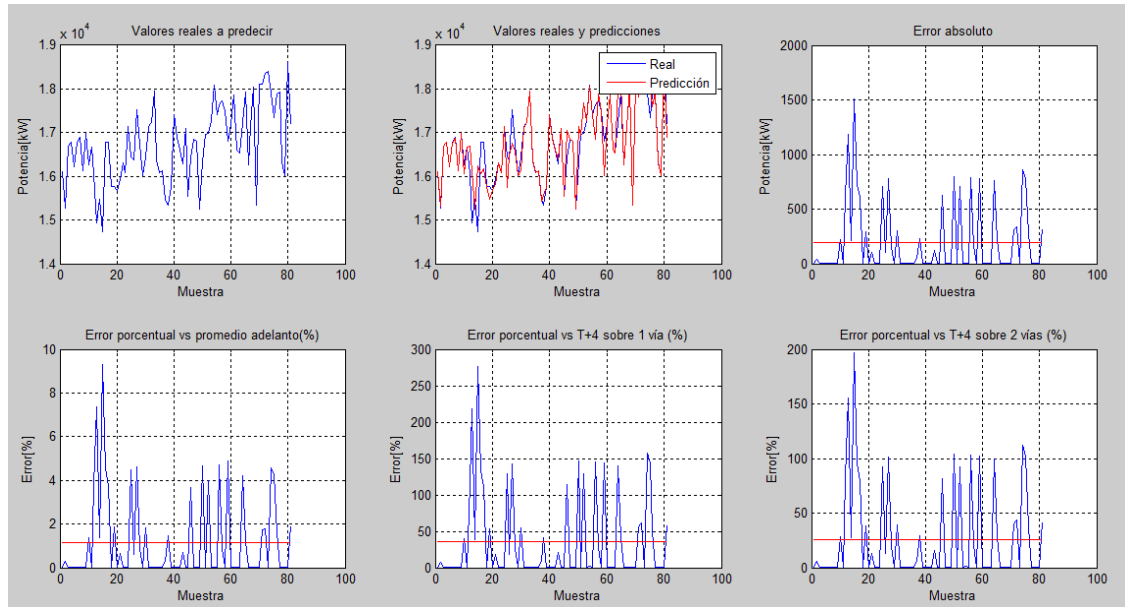


Ilustración 112 – Resultados de las predicciones.

3.3.3.2.19. Predicción a las 19:35 hrs.

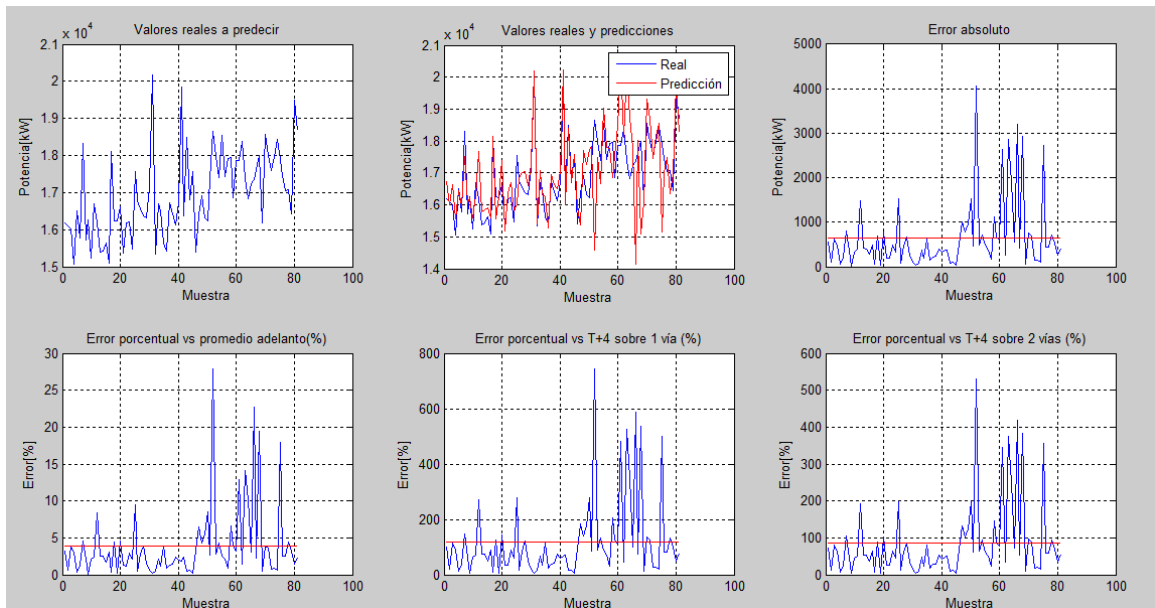


Ilustración 113 – Resultados de las predicciones.

3.3.3.2.0. Predicción a las 19:40 hrs.

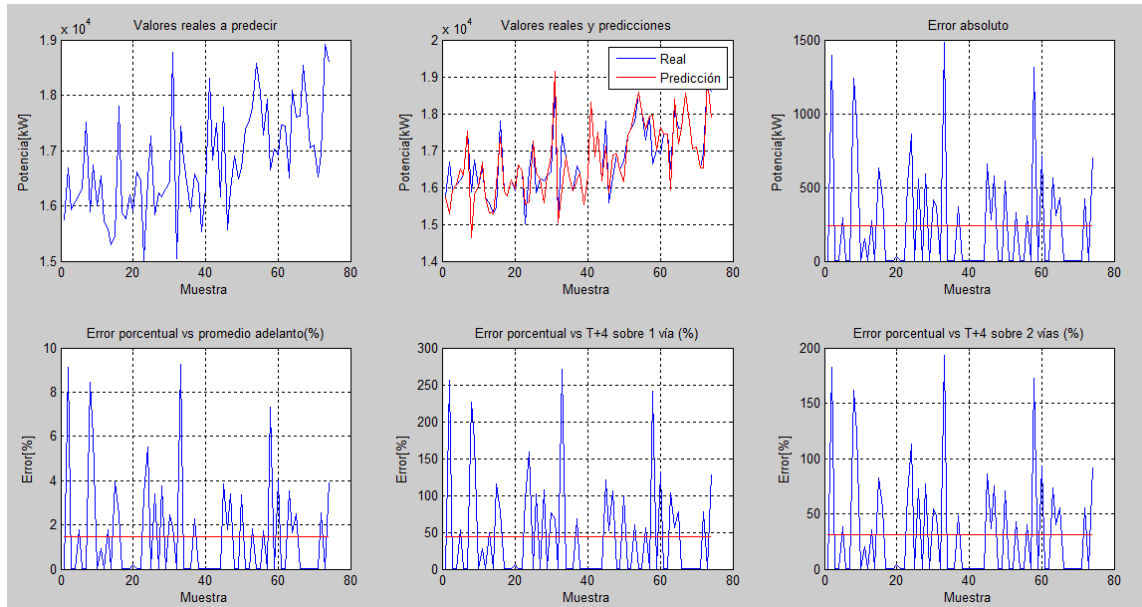


Ilustración 114 – Resultados de las predicciones.

3.3.3.2.1. Predicción a las 19:45 hrs.

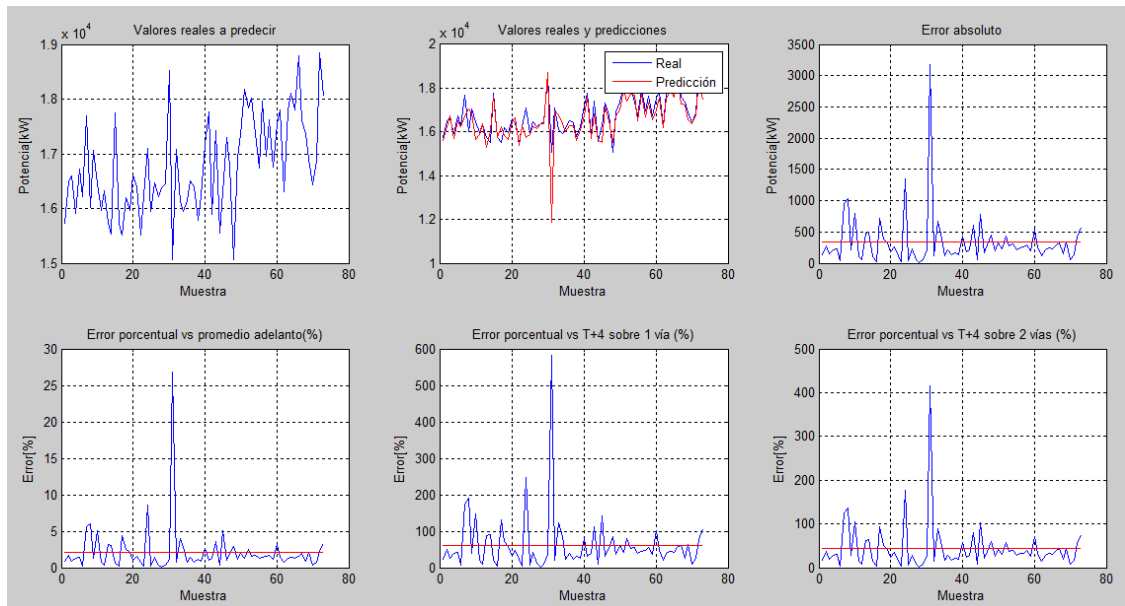


Ilustración 115 – Resultados de las predicciones.

3.3.3.2.2. Predicción a las 19:50 hrs.

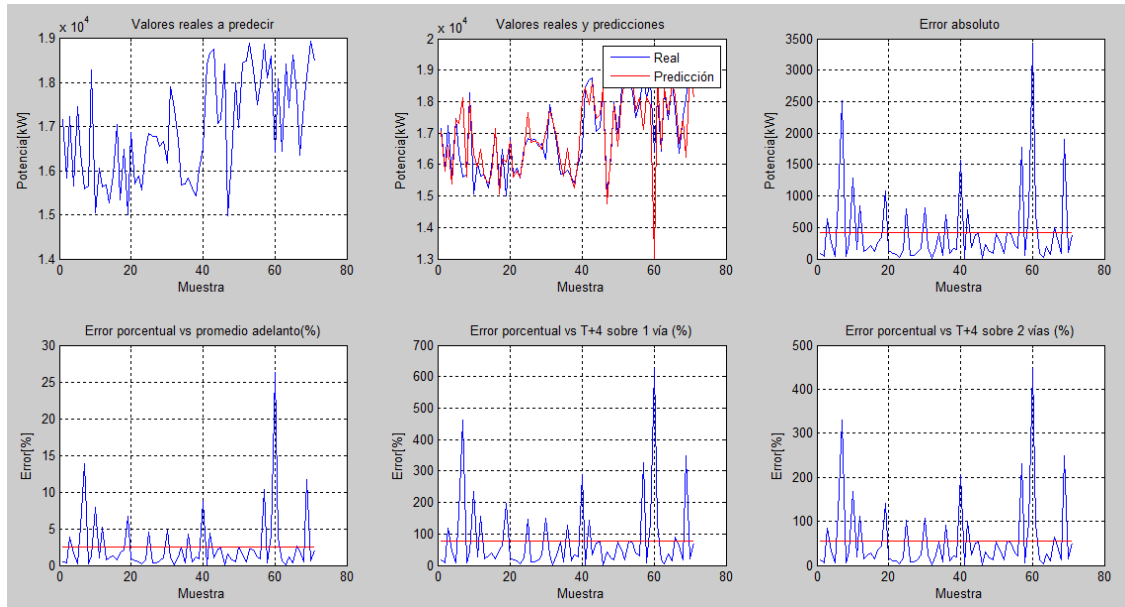


Ilustración 116 – Resultados de las predicciones.

3.3.3.2.3. Predicción a las 19:55 hrs.

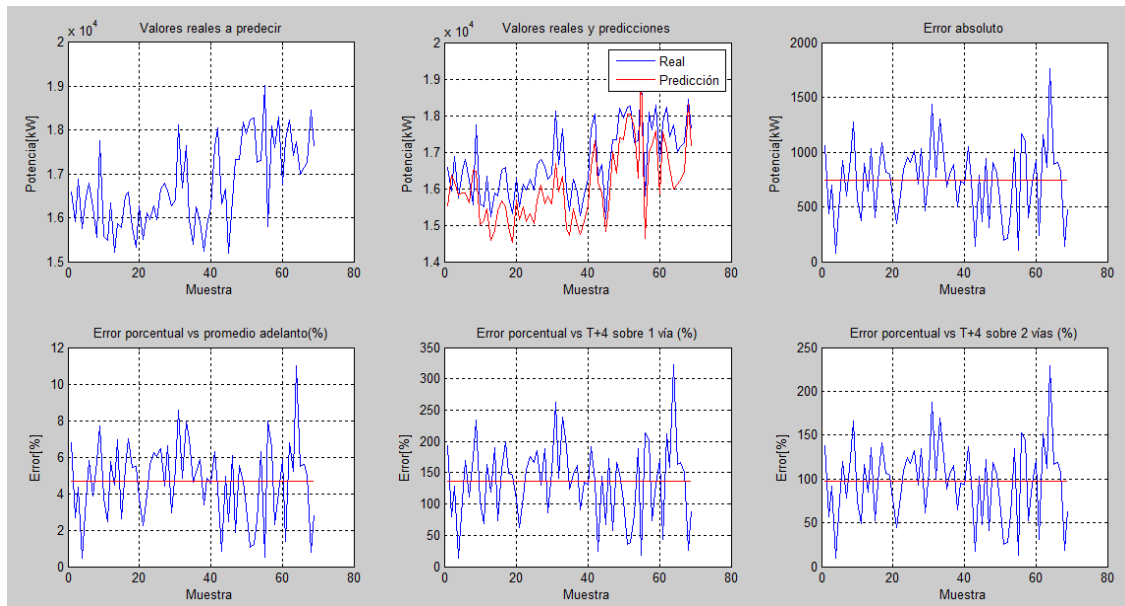


Ilustración 117 – Resultados de las predicciones.

3.3.3.2.24. Predicción a las 20:00 hrs

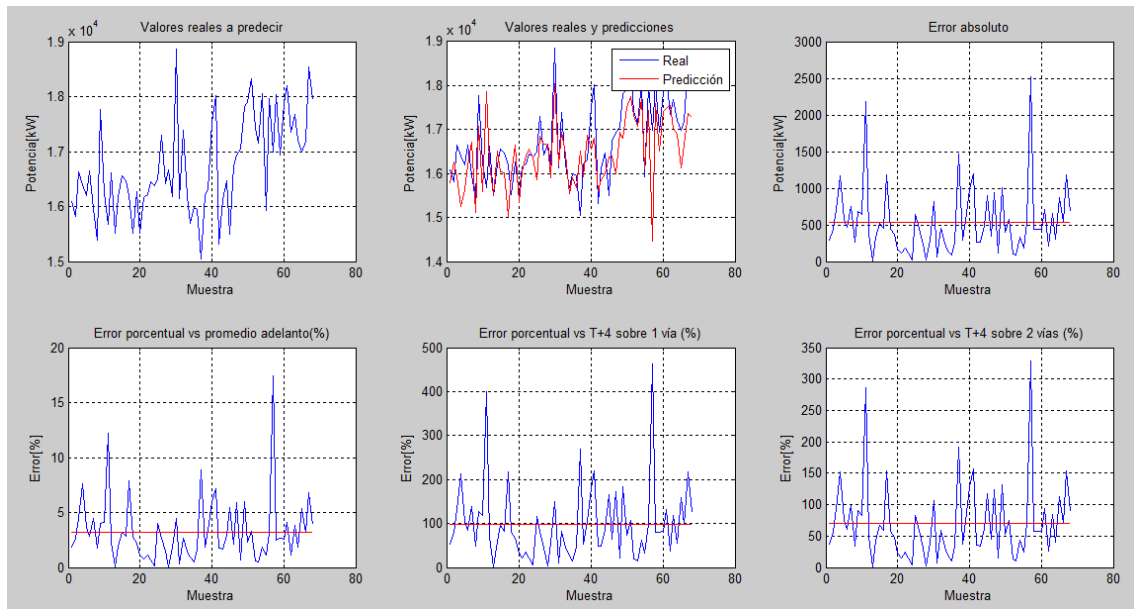


Ilustración 118 – Resultados de las predicciones.

4. CONCLUSIONES Y RECOMENDACIONES

Al finalizar el análisis de los resultados que se obtuvieron de las predicciones de las 48 redes neuronales para los sistemas CDC-VV y SEAT, se comprueba la efectividad que posee esta poderosa herramienta a la hora de efectuar predicciones de series de tiempo.

Mediante sucesivas implementaciones de distintas arquitecturas de red se fue evolucionando en la determinación de modelos matemáticos que permitiesen obtener predicciones cada vez más acertadas.

En un comienzo se postuló la idea de realizar predicciones cada 15 minutos, sin embargo, durante el transcurso de las simulaciones se pudo ver que la variable potencia eléctrica demandada por Metro S.A a lo largo del tiempo poseía fluctuaciones demasiado intensas como para ser estudiadas a lo largo de un período muy extenso.

Al probar con redes neuronales que predecían demandas de potencia 5 minutos a futuro se obtuvieron resultados mucho más certeros. Si bien, esta idea no calza con lo que se planteó desde un principio, sí va acorde a las exigencias que debiese tener el sistema de predicción que se buscó en los objetivos de este problema de ingeniería.

Tomando en cuenta que las medidas de control que existen en la actualidad tienen un impacto directo en la demanda de potencia de Metro S.A. que no demora más allá de tres minutos, esta información entregada por los expertos del panel de control de demanda de Metro S.A. fue preponderante a la hora de tomar la decisión de realizar las predicciones a 5 minutos.

Por otra parte, la separación del análisis de demanda de potencia de Metro S.A. en dos subsistemas, el Centro de distribución de Carga Vicente Valdés (CDC-VV) y la Subestación Eléctrica de Alta Tensión (SEAT) permitieron realizar un estudio mucho más detallado del sistema dinámico, debido a que ambos sistemas poseen alimentaciones y cargas por separado, lo cual influye directamente en su comportamiento dinámico. Cabe agregar también que el control de demanda se realiza para cada línea por separado, razón por la cual es pertinente realizar una separación de ambos subsistemas.

Los resultados de las predicciones fueron excelentes. Tomando en cuenta los errores porcentuales de las predicciones respecto a las demandas de potencia reales del sistema en el instante de la predicción se pudo visualizar errores que no eran superiores al 3,5 % en el SEAT y 5% en CDC-VV. Además, el promedio de los errores porcentuales para todas las redes neuronales fue de aproximadamente 1,6% en el SEAT y 2,5 % en CDC-VV.

Errores de una magnitud promedio bajo el 2,5 % son bastante aceptables para la predicción de un sistema dinámico con fluctuaciones no menores como lo es la demanda de potencia eléctrica de Metro S.A. Además, se tomó en cuenta las estrategias de control que se implementan hoy en día en Metro para mitigar la demanda de potencia eléctrica y se obtuvo en promedio para el SEAT que el error porcentual correspondía aproximadamente a un 46% de el efecto que tiene la medida de solución T+4 en una vía para la mitigación de la demanda de potencia de Metro S.A., esto indica que la medida de solución siempre será más potente que el error que puedan cometer las predicciones, por lo que el sistema siempre se encontrará bajo control. Para el CDC-VV se tuvo que el error porcentual promedio corresponde aproximadamente a un 75% del efecto que tiene la aplicación de un T+4 en una vía, por lo que el sistema también estaría bajo control.

Cabe destacar que el CDC-VV tiene una demanda de potencia que es cercana al 21,9 % de la totalidad de demanda de Metro S.A., razón por la cual los errores porcentuales son menores, debido a que la demanda de potencia considerada como el 100% para realizar el cálculo del promedio es mucho menor a la demanda de potencia del SEAT. Además, el SEAT siendo el sistema más importante posee predicciones muy certeras, lo que implica que si se considera la totalidad de Metro, el sistema siempre estará bajo un control adecuado.

Claramente si se aplica un control T+4 a ambas vías de cada línea, el efecto de esta solución será más fuerte que el de la medida anterior, por lo cual el sistema estará más seguro aún. En este caso, para el SEAT se tuvo que el error porcentual correspondía a un 33 % de la medida de solución y para el CDC-VV correspondió a un 53% aproximadamente.

Con los resultados anteriores se llega a la conclusión de que las redes neuronales entrenadas con los datos provenientes del sistema SCADA de supervisión y adquisición de datos de Metro S.A. están listas para realizar predicciones de la demanda de potencia eléctrica de los sistemas CDC-VV y SEAT para el año vigente.

Las predicciones que se pueden realizar a lo largo del año actual, permitirían conocer la demanda futura de potencia eléctrica de ambos subsistemas, y con esto se podrían efectuar aplicaciones de medidas como T+4 en una vía o T+4 en 2 vías con una metodología mucho más óptima que la actual.

Hoy en día se aplica T+4 en una vía para todas las líneas de Metro de forma continua en el horario de punta de la tarde. Esto implica que los trenes que recorren las distintas líneas de Metro S.A. entre las 18:00 y las 20:00 hrs realizan sus viajes con una velocidad menor a la velocidad promedio, demorándose 4 segundos más por cada tramo inter-estación.

Lo anterior se ejecuta de esa forma debido a que se debe cumplir con reglas internas en Metro, que tienen que ver principalmente con el contrato de suministro de energía que sostiene Metro con una empresa comercializadora de energía en particular. Es así como se establecen niveles máximos de demanda de potencia para distintos instantes dentro del rango entre las 18:00 y las 20:00 hrs.

Si se empiezan a aplicar las predicciones de la demanda de potencia de ambos subsistemas, ya no sería necesario aplicar de forma continua los métodos de mitigación de potencia T+4, esto debido a que la predicción permitiría saber si los niveles de demanda de potencia sobrepasarán los niveles establecidos bajo el contrato de energía.

Si se realiza un simple cálculo para una línea en particular de Metro, por ejemplo la línea 5 que posee 30 estaciones. En la actualidad el retardo de 4 segundos por tramo inter-estación implica que un tren que viene desde la estación “depart” Maipú y se dirige hacia la estación “arrive” Vicente Valdés demoraría 4·29 segundos más en llegar a destino, es decir, aproximadamente 2 minutos más de tiempo de viaje.

Tomando en cuenta el caso anterior, y pensando en las personas que deben realizar ese recorrido para ir a sus trabajos, ellos demorarán aproximadamente 4 minutos más de lo normal en un viaje de ida y vuelta. Si bien 4 minutos no es demasiado tiempo, sí lo es cuando se piensa en el confort de las personas que viajan en el horario punta donde se tienen en promedio 6 personas por metro cuadrado.

La aplicación de las predicciones para realizar un control de demanda más óptimo de la potencia permitiría en ciertos casos reducir estos 4 minutos de tiempo muerto que se tienen hoy en día, por un número menor dentro de las posibilidades que permita la gestión de demanda de Metro.

Si llevamos lo anterior a las demás líneas, y si se piensa que se podría aplicar a trenes que salen del depart de una línea en distintos instantes dentro del horario punta, se podrá concluir que la aplicación de un control apoyado por las predicciones de las redes neuronales podría mejorar el confort de miles de personas que utilizan el Metro a diario como medio de transporte.

5. BIBLIOGRAFÍA

Apuntes Conversión Electromecánica de la Energía - 2003

Apuntes curso Tracción Eléctrica - 2009

Apuntes de Redes Neuronales y Teoría de Información para el aprendizaje - 2011

Comisión Nacional de Energía 2011 - *Informe Técnico Definitivo*

Curso GLISA Redes Neuronales - 2003

Haykin, S. (1999). *NEURAL NETWORKS A - Comprehensive Foundation Second Edition*. Canada: PEARSON Prentice Hall.

Matlab 2011 - www.mathworks.com

Metro S.A. - 2011 - *Libro Funcional L3, L6*

METRO S.A. - 2011 - www.metro.cl

Predicción de series temporales con redes neuronales: una aplicación a la inflación colombiana
- 2006 - *Revista Colombiana de Estadística* 291 - 77 a 92

www.ibiblio.org