

**Parodi, M. ; Herrera, L. ; Matar, M. ; Barrea, L. ; Mechni, M.
; Masramón, E. ; Luccini, E.**

Redes neuronales artificiales aplicadas al análisis de datos en ingeniería ambiental e impacto ambiental

Energeia, Año 12, N° 12, 2014

Este documento está disponible en la Biblioteca Digital de la Universidad Católica Argentina, repositorio institucional desarrollado por la Biblioteca Central "San Benito Abad". Su objetivo es difundir y preservar la producción intelectual de la Institución.

La Biblioteca posee la autorización del autor para su divulgación en línea.

Cómo citar el documento:

Parodi, M., et al. Redes neuronales artificiales aplicadas al análisis de datos en ingeniería ambiental e impacto ambiental [en línea]. *Energeia*, 12(12), 2014. Disponible en:
<http://bibliotecadigital.uca.edu.ar/repositorio/revistas/redes-neuronales-artificiales-datos.pdf> [Fecha de consulta:]

Redes Neuronales Artificiales aplicadas al análisis de datos en Ingeniería Ambiental e Impacto Ambiental

M. Parodi^{1,2,3}, L. Herrera¹, M. Matar^{1,3}, L. Barrea^{1,2}, M. Mechni¹, E. Masramón¹ y E. Luccini^{1,2}

¹ Facultad de Química e Ingeniería, Pontificia Universidad Católica Argentina, Rosario.

² Instituto de Física de Rosario, CONICET/Universidad Nacional de Rosario.

³ Facultad de Ciencias Exactas, Ingeniería y Agrimensura, Universidad Nacional de Rosario.

Resumen: Se realiza una revisión sobre los antecedentes de las Redes Neuronales Artificiales (RNA) como método de análisis de bases de datos medioambientales, aplicado en las diversas áreas de la Ingeniería Ambiental en general y de Impacto Ambiental en particular. Se describe como ejemplo, la aplicación de RNA en los algoritmos de inversión de datos obtenidos por sensado remoto satelital, para la medición de variables geofísicas

Palabras Clave: Datos Medioambientales, Ingeniería Ambiental, Impacto Ambiental, Redes Neuronales Artificiales, Sensado Remoto

Abstract: A review of the history of Artificial Neural Networks (ANN) as a method of analysis of environmental data, applied to different areas of Environmental Engineering in general, and Environmental Impact in particular is presented. As an example, ANN applications dealing with the satellital remote measurements of geophysical variables are described.

Keywords: Environmental Data, Environmental Engineering, Environmental Impact, Artificial Neural Networks, Remote Sensing

Introducción

Acorde a la definición de Gómez Orea (1988), el Medio Ambiente “es el entorno vital, el conjunto de factores físico-naturales, sociales, culturales, económicos y estéticos que interactúan entre sí, con el individuo y con la comunidad en la que vive, determinando su forma, carácter, relación y supervivencia. No debe confundirse pues, como el medio envolvente del hombre, sino como algo indisociable de él, de su organización y de su progreso”.

El Principio 17 de la Declaración de Río del año 1992 [CNUMAD, 1992] establece que “Deberá emprenderse una evaluación del impacto ambiental, en calidad de instrumento nacional, respecto de cualquier actividad propuesta que probablemente haya de producir un impacto negativo considerable en el medio ambiente y que esté sujeta a la decisión de una autoridad nacional competente”.

Sobre la base de distintas referencias, Arboleda González (2008) define el concepto de Impacto Ambiental como “el cambio que se ocasiona sobre una condición o característica del ambiente por efecto de un proyecto, obra o actividad. Este cambio puede ser beneficioso o perjudicial según mejore o deteriore el ambiente, puede producirse en cualquier etapa del ciclo de vida de los proyectos y tener diferentes niveles de importancia”. Distingue a su vez entre Estudio de Impacto Ambiental “que se presenta a la autoridad ambiental para obtener una licencia” y un concepto mucho más amplio denominado Evaluación de Impacto Ambiental, una herramienta que permite determinar, no sólo las consecuencias ambientales de cualquier emprendimiento, sino también proponer las acciones necesarias para atender dichas secuelas. Define entonces la Evaluación de Impacto Ambiental como un “instrumento o herramienta de carácter preventivo, encaminado a identificar las consecuencias ambientales de la ejecución y funcionamiento de una actividad humana, con el fin de establecer las medidas preventivas y de control que hagan posible el desarrollo de la actividad sin perjudicar, o perjudicando lo menos posible, al medio ambiente”.

Canter y Sadler (1997) clasificaron las metodologías para la Evaluación del Impacto Ambiental en 22 grupos (listados alfabéticamente en idioma inglés), como puede verse en la Tabla 1.

Tabla 1. Clasificación, según Canter y Sadler, de las metodologías para la Evaluación de Impacto Ambiental.

Método	Características
1. <i>Analógico</i>	Se remite a la información de proyectos existentes de un tipo similar al que está siendo analizado por un estudio de impacto. La información obtenida en la medición y seguimiento de los impactos ambientales actuales puede ser usada como una analogía a los impactos anticipados del proyecto propuesto.
2. <i>Lista de chequeo</i>	Típicamente, la lista de chequeo contiene una serie de puntos, asuntos de impacto o cuestiones que el usuario atenderá o contestará como parte del estudio de impacto.
3. <i>Listas de chequeo enfocadas a decisiones</i>	Representan un grupo de métodos los cuales están inicialmente referidos a comparar alternativas y conducir a un análisis de equilibrio.
4. <i>Análisis ambiental costo – beneficio</i>	Este método complementa el tradicional análisis coste beneficio con una atención adicional a los recursos naturales y su valor económico.
5. <i>Opinión de expertos (dictamen profesional)</i>	Las herramientas específicas dentro de esta categoría que pueden utilizarse para delinear información, incluyen estudios Delphi y el uso del proceso adaptativo de evaluación ambiental.
6. <i>Sistema experto</i>	Consiste en recolectar el conocimiento profesional y el juicio de expertos en áreas temáticas específicas y de actualidad.
7. <i>Índices o indicadores</i>	Se refiere a características específicas o integradas de factores medioambientales o recursos. Se utilizan dentro de los estudios de impacto para representar parámetros de amplitud de medios o recursos.
8. <i>Pruebas de laboratorio y modelos a escala</i>	Se pueden aplicar para conseguir información cualitativa - cuantitativa sobre impactos anticipados de un determinado tipo de proyecto en una localización geográfica dada.
9. <i>Evaluación de paisajes</i>	Inicialmente útil para la valoración de recursos estéticos o visuales. Esta información puede ser usada como representativa de las condiciones de partida.
10. <i>Revisión bibliográfica</i>	Supone ensamblar información sobre los tipos de proyectos y su impacto típico. Este tipo de información puede ser útil para la pronta definición de impactos potenciales.
11. <i>Cálculo de balance de materia</i>	Basado inicialmente en inventarios de condiciones existentes para compararlas con los cambios que resultarán de una acción propuesta.
12. <i>Matrices de interacción</i>	Las variaciones de las matrices sencillas de interacción han sido desarrolladas para enfatizar rasgos característicos deseables.
13. <i>Monitorización</i>	Se refiere a mediciones sistemáticas para establecer las condiciones existentes de los ambientes afectados. Puede enfocarse a los ambientes fisicoquímico, biológico, cultural y/o socioeconómico.
14. <i>Estudio de campo</i>	Es específicamente, la monitorización y análisis de impactos evidentes, manifestados actualmente a consecuencia del proyecto.
15. <i>Redes</i>	Se refieren a un grupo de métodos que definen las conexiones o relaciones entre las acciones proyectadas e impactos resultantes.
16. <i>Superposición de mapas</i>	La superposición cartográfica de transparencias (en forma física o digitalizada) se usa para describir condiciones existentes y desplegar cambios potenciales resultantes de la acción propuesta.
17. <i>Fotografías o fotomontajes</i>	Son útiles como herramientas para mostrar la calidad visual del medioambiente seleccionado e identificar los potenciales impactos visuales de la acción propuesta.

Método	Características
18. <i>Modelización cualitativa</i>	Se refiere a un grupo de métodos en el que la información descriptiva es utilizada para relacionar varias acciones con cambios resultantes en los componentes ambientales.
19. <i>Modelización cuantitativa (matemática)</i>	Se refiere a un extenso grupo de métodos usados para atender, anticipadamente, a los cambios en el medio ambiente o en los recursos naturales, como resultados de acciones propuestas. Tales modelos pueden variar desde versiones simplificadas a muy complicadas simulaciones computacionales.
20. <i>Evaluaciones de riesgo</i>	Estos métodos abarcan la identificación de los riesgos, consideraciones sobre la relación dosis-respuesta y evaluación del riesgo asociado.
21. <i>Construcción de escenarios</i>	Involucra consideraciones alternativas futuras como resultado de suposiciones iniciales diferentes.
22. <i>Extrapolación de tendencias</i>	Utiliza tendencias históricas y las proyecta al futuro basándose en suposiciones asociadas a condiciones de cambio continuo.

Para la realización de todo abordaje sobre Impacto Ambiental, hay dos elementos fundamentales; uno es la obtención de datos medioambientales y el otro, las herramientas matemáticas para su análisis. Sobre este último aspecto trata este trabajo, haciendo énfasis en las Redes Neuronales Artificiales como método de análisis aplicado particularmente al manejo de bases de datos medioambientales, relevando aplicaciones en las diversas áreas de la Ingeniería Ambiental, en general y de Impacto Ambiental, en particular. Se describe como ejemplo el empleo de RNA en el tratamiento de grandes bases de datos provenientes de sensores remotos satelitales.

Variables de interés en Ingeniería Ambiental y en Impacto Ambiental

Conesa Fernández-Vítora (1995) define el Medio Natural como el “Sistema constituido por los elementos y procesos del ambiente natural tal como lo encontramos en la actualidad y sus relaciones con la población” y se proyecta en tres subsistemas: *Medio Físico* propiamente dicho: Aire, Tierra y Agua; *Medio Biótico*: Flora y Fauna, y *Medio Perceptual*: Unidades de paisaje (cuencas visuales, valles y vistas). Espinoza (2007) plantea, como puede verse en la Tabla 2, la identificación de los indicadores de causa y de estado para el abordaje de diversas problemáticas ambientales.

Tabla 2. Identificación, según Espinoza, de los Indicadores de Causa y de Estado para el abordaje de diversas problemáticas ambientales.

Parámetro Problema	Ejemplos de Indicadores de Causa	Ejemplos de Indicadores de Estado
<i>Cambio Climático</i>	Emisiones de gases de efecto invernadero. Emisiones de CO ₂ .	Concentración atmosférica de gases de efecto invernadero. Temperatura media global.
<i>Contaminación del agua</i>	Intensidad de uso de los recursos de agua. Extracción anual de aguas superficiales y subterráneas. Consumo doméstico per cápita de agua. Descargas domésticas e industriales en cuerpos de agua.	Frecuencia, duración y extensión de los períodos de escasez de agua. Concentraciones de Pb, Cd, Hg y pesticidas en cuerpos de agua dulce. Concentración de coliformes fecales en cuerpos de agua. Temperatura de las aguas.

Parámetro Problema	Ejemplos de Indicadores de Causa	Ejemplos de Indicadores de Estado
<i>Eutroficación</i>	Emisiones de N y P en agua y suelos. Usos de N y P en alimentos de cultivos acuáticos. Usos de N y P en fertilizantes y alimentos para ganado.	Demanda biológica de Oxígeno/Oxígeno Disuelto. Concentraciones de N y P en aguas continentales y en aguas marinas.
<i>Acidificación del agua y de los suelos</i>	Índice de sustancias acidificantes. Emisiones de SOx y NOx.	Excedencia de valores críticos de pH en agua y suelos. Concentraciones de precipitación ácida.
<i>Calidad ambiental urbana</i>	Tasa de crecimiento de población urbana. Número de vehículos en uso. Inventario de industrias contaminantes. Emisiones en el aire urbano (SOx, NOx, COx). Densidad de tráfico urbano nacional. Grado de urbanización. Niveles de ruido.	Porcentaje de población en áreas urbanas. Áreas y población en asentamientos marginales. Población expuesta a: contaminación del aire y ruido. Condiciones ambientales del agua en zonas urbanas. Índice de viviendas por estado de conservación. Porcentaje de población con servicios sanitarios.
<i>Contaminación atmosférica</i>	Inventario de fuentes fijas y móviles. Número y tasas de incremento del parque industrial y automotriz. Emisiones de metales pesados. Emisiones de compuestos orgánicos.	Concentraciones de partículas, micropartículas y gases en la atmósfera. Niveles de contaminación de suelos, aguas y bosques por inmisión y deposición. Concentración de metales pesados y compuestos orgánicos en el ambiente y en especies vivas.
<i>Conservación de la biodiversidad/paisaje</i>	Alteración de hábitats y preservación de tierras en estado natural. Tasas anuales de producción de maderas. Tasas anuales de consumo de leña. Tasas anuales de exportación de especies endémicas.	Participación de las especies amenazadas o en extinción en el total de las especies conocidas. Cambios de biomasa. Tasa de extinción de especies protegidas. Tasas relativas de deforestación/forestación.
<i>Residuos</i>	Generación de residuos municipales, industriales y nucleares peligrosos. Emisiones de metales pesados. Emisiones de compuestos orgánicos. Consumo de pesticidas. Minería a cielo abierto que vierte desechos contaminantes al ambiente y deja material venenoso sobre el terreno.	Área de terreno contaminada por desechos tóxicos. Calidad del aire, agua y suelo contaminados. Calidad de la biota y ecosistemas afectados. Efectos sobre la salud humana.
<i>Degradación de la tierra y del suelo (desertificación y erosión)</i>	Riesgos de erosión. Uso actual y potencial del suelo para la agricultura. Capacidad de carga (cabezas de ganado por unidad de superficie)	Área afectada según grado y tipo de erosión. Índices de erosión (p. ej.: producción de sedimentos). Porcentaje de pérdida del horizonte A del suelo. Superficie afectada por desertificación.

Aplicaciones de RNA en Ingeniería Ambiental y en Impacto Ambiental

La Tabla 3 especifica cronológicamente algunas de las referencias más recientes y completas referidas a aplicaciones de RNA en el ámbito medioambiental.

Tabla 3. Aplicaciones más recientes de RNA en el ámbito medioambiental.

Autores	Título	Ámbito de aplicación de RNA	Año y tipo de publicación
<i>Polyakov, A.V.</i>	The method of artificial neural networks in retrieving vertical profiles of atmospheric parameters. Atmospheric and Oceanic Optics. Vol. 27, Issue 3, pp 247-252.	Parámetros atmosféricos	2014. Paper.
<i>Banan N., M. Talib Latif, L. Juneng, M. F. Khan</i>	From Sources to Solution. Proceedings of the International Conference on Environmental Forensics 2013. Chapter 2: An Application of Artificial Neural Networks for the Prediction of Surface Ozone Concentrations in Malaysia. ISBN: 978-981-4560-69-6 (Print) 978-981-4560-70-2 (Online) Springer, pp 7-12.	Contaminación atmosférica en superficie	2014. Libro.
<i>Krasnopolsky, V.M.</i>	The Application of Neural Networks in the Earth System Sciences. Neural Networks Emulations for Complex Multidimensional Mappings. Atmospheric and Oceanographic Sciences Library. Vol. 46, ISBN: 978-94-007-6072-1 (Print) 978-94-007-6073-8 (Online) Springer.	Sensado remoto en atmósfera y océanos. Modelos numéricos de clima y meteorología.	2013. Libro.
<i>Baños, R., F. Manzano-Agugliaro, F.G. Montoya, C. Gil, A. Alcayde, J. Gómez</i>	Optimization Methods Applied to Renewable and Sustainable Energy: A Review. Renewable and Sustainable Energy Reviews. Vol. 15, No.4, pp 1753-1766.	Energías renovables	2011. Paper (Review)

Redes Neuronales y mediciones de variables geofísicas a partir de mediciones con sensores remotos

En geociencias como la Meteorología, Oceanografía, Climatología y en la modelización y protección del medioambiente y ecosistemas, es un problema de gran interés la estimación de valores de variables geofísicas que midan las propiedades físicas, químicas y biológicas de los océanos, atmósfera y superficie terrestre, a partir de mediciones remotas (con sensores a bordo de satélites, aviones, globos, etc.) de propiedades de la radiación electromagnética relacionadas con los valores de dichas variables, o el cambio de ellos en el espacio y en el tiempo (RS, del inglés *Remote Sensing*. En español, *Teledetección*). Estas mediciones, en particular las realizadas con instrumentos a bordo de satélites, permiten la obtención de altas densidades espaciales de datos globales y sobre el nivel del suelo y la superficie del océano. De por sí, las mediciones remotas son usualmente muy certeras, mientras que la calidad de los valores de las variables geofísicas derivadas de estas mediciones dependerá, por un lado, de la intensidad y univocidad de la señal electromagnética generada por las variables geofísicas y, por otro lado, estará significativamente afectada por los métodos matemáticos aplicados para extraer los valores de estas variables; es decir, los métodos que resuelven, como se explica más abajo, los problemas directo e inverso en el campo de RS.

Obtención de variables geofísicas con sensores remotos satelitales

Para inferir variables geofísicas a partir de mediciones con sensores remotos a bordo de satélites, se recurre a técnicas “de recuperación” o “inversión”. Estos procedimientos relacionan radiancias, temperaturas de brillo y otras propiedades

de la radiación electromagnética provenientes de los océanos, atmósfera y superficie terrestre con concentración de fitoplancton, aerosoles atmosféricos, humedad de la vegetación, etc. Tales datos se utilizan luego de modo puntual o a escala de amplias regiones planetarias para inferir otros parámetros ([Cede et al., 2004], [Luccini et al., 2006]). Las técnicas de recuperación se clasifican en las llamadas estándar o tradicionales (SR, del inglés, *Standard Retrieval*) y en las denominadas variacionales o de asimilación directa de datos (VRT, del inglés, *Variational Retrieval Techniques*). Las técnicas SR utilizan mediciones tomadas con un único sensor remoto, para estimar una o varias variables geofísicas; mientras que las técnicas VRT emplean un completo *sistema de asimilación de datos* provenientes de distintos sensores satelitales y también de boyas, radiosondas, barcos, aeronaves, etc. La Figura 1 ilustra el flujo de datos desde los instrumentos a los usuarios [Krasnopolsky et al., 2003]. Los modelos “directos” (*Forward Models*), los cuales simulan las mediciones satelitales a partir de valores de las variables geofísicas y los algoritmos “inversos” (*Retrieval Algorithms*), que transforman los datos satelitales en valores de variables geofísicas, cumplen el rol de mediadores entre los sensores satelitales y los usuarios.

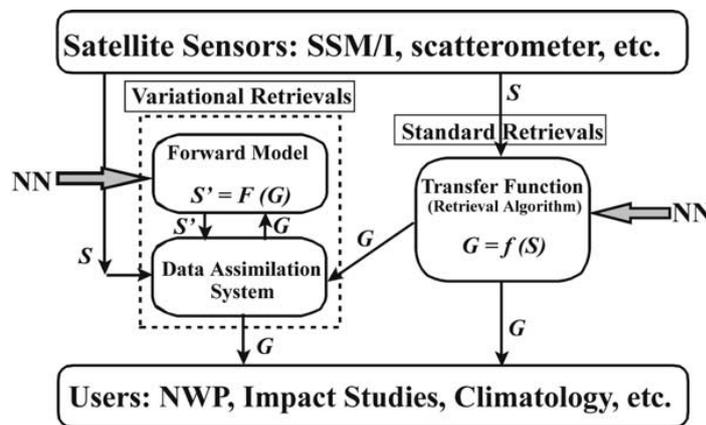


Figura 1. Esquema del procesamiento para la obtención de variables geofísicas a partir de mediciones satelitales. Las redes neuronales (NN) optimizan los convertidores de datos TF y FM en el proceso [Krasnopolsky et al., 2003].

- *Método SR*

El método SR debe resolver el problema de inversión mencionado más arriba, derivando una función de transferencia f (TF, *Transfer Function*); ésta relaciona una medición del sensor a bordo de un satélite, S (coeficiente de retrodispersión, radiancia, etc.) con una variable geofísica G ; por ejemplo, velocidad del viento sobre la superficie del mar, concentración de la humedad atmosférica, temperatura de la superficie del mar, etc. En el caso más general, S y G son vectores tales que,

$$G = f(S) \quad (1)$$

La función TF, f , no puede ser derivada directamente de primeros principios pues un único vector S puede corresponder a múltiples valores de G . Sin embargo, se puede escribir la relación inversa a la dada por la Ec. (1),

$$S = F(G) \quad (2)$$

donde la función F es un modelo FM (*Forward Model*) derivado de consideraciones físicas (por ejemplo, la teoría de transferencia radiativa). Así, resulta que la Ec. (2) representa un problema *bien definido* (*well-posed problem*) en contraposición con el representado por la Ec. (1), que es un problema *mal definido* (*ill-posed problem*). Un problema bien definido es un sistema de ecuaciones diferenciales en derivadas parciales con condiciones iniciales, que tiene única solución y ésta depende de manera continua de los valores iniciales ([Hadamard, 1902], [Parker, 1994]).

Para derivar la TF que satisface la Ec. (1), debe invertirse FM (la función F en la Ec. (2)). La técnica de inversión usual [Stoffelen et al., 1997] se aplica a la búsqueda del vector G^0 que minimiza la funcional

$$\|\Delta S\| = \|S^0 - F(G)\| \quad (3)$$

donde S^0 es un vector de mediciones satelitales. Como F (FM) es una función no lineal complicada, el problema no lineal de optimización debe resolverse numéricamente sobre todo el espacio de las variables geofísicas involucradas y adolece de dificultades como lenta convergencia, multiplicidad de soluciones, etc. Este método no determina f (TF) explícitamente, sino que la supone implícita y, para cada nueva medición S^0 , debe repetirse todo el proceso.

Si se tiene un vector G^0 que se aproxima al vector G y que, al mismo tiempo, minimiza la funcional ΔS de la Ec. (3), entonces, la función $F(G)$ puede ser expandida en una serie de Taylor, alrededor de $G = G^0$ de manera que se obtiene un sistema de ecuaciones lineales [Wentz, 1997]:

$$\sum_{i=1}^n \frac{\partial F(G)}{\partial G_i} \Big|_{G=G^0} \Delta G_i = S^0 - F(G^0) \quad (4)$$

donde n es la dimensión del vector G y ΔG_i es la diferencia entre la componente i -ésima de este vector y la correspondiente componente del vector inicial G^0 .

El sistema definido por las Ecs. (4) permite calcular las componentes del vector ΔG . Una vez calculado éste, se realiza la próxima iteración de las Ecs. (4) con el reemplazo del vector G^0 por el vector $G^0 + \Delta G$. El proceso converge rápidamente al vector G , sin determinarse explícitamente TF; sólo se calcula implícitamente el valor de la función f para el caso del vector S^0 .

Los procesos de recuperación o inversión descritos hasta aquí, Ecs. (3) y (4), son denominados “locales”. Dado que, además, requieren el conocimiento de la función FM, son llamados usualmente métodos de inversión basados en “primeros principios” o fundamentados “físicamente”. También pueden clasificarse dentro de los algoritmos *multivariados*, pues recuperan simultáneamente varios valores de distintas variables geofísicas; esto es, *todas* las componentes del vector G .

Otro tipo de algoritmos para implementar el método SR, que no están fundamentados en primeros principios, son los algoritmos *empíricos*. Éstos asumen la existencia de una ley analítica explícita de TF; es decir, de la función f . Si bien esta ley es desconocida *a priori*, los algoritmos empíricos de inversión construyen un modelo estadístico f_{mod} que contiene un vector de parámetros de ajuste empíricos $a = (a_1, a_2, a_3, \dots)$, de manera que una determinada componente del vector G , G_k , puede escribirse como

$$G_k = f_{\text{mod}}(S, a) \quad (5)$$

El ajuste que determina los parámetros del vector a se hace aplicando técnicas estadísticas, como el método de mínimos cuadrados, a un conjunto de datos de pares correspondientes (empíricos o simulados) $\{G_k, S\}$. A diferencia de las inversiones definidas por las Ecs. (3) y (4), el tipo de técnicas de regresión con las que se obtienen las funciones f_{mod} que satisfacen la Ec. (5), se categorizan como “globales”, porque emplean todo el conjunto de datos del sensor (todos los vectores S), mientras que las técnicas “locales” se aplican a un único vector S^0 . También, en contraste con las inversiones descritas por las Ecs. (3) y (4), la mayoría de los algoritmos de inversión empíricos son univariados pues se aplican a una única componente, G_k , del vector G . Por ejemplo, sólo en la recuperación de velocidad del viento [Goodberlet, 1989] o vapor de agua ([Alishouse, 1990], [Petty, 1993]). Los algoritmos de inversión empíricos univariados tienen mayores errores sistemáticos (*bias*) y aleatorios (variancia) para la variable geofísica G_k que las técnicas de inversión multivariadas [Krasnopolsky et al., 1999, 2000]. Para mejorar las inversiones empíricas univariadas, en la regresión se recurre a incorporar todas las otras componentes, relacionadas entre sí físicamente, del vector G y que contribuyen juntas al vector S . Así, se invierten los datos satelitales en el espacio completo de las variables geofísicas, como hacen las técnicas multivariadas basadas en primeros principios, Ecs. (3) y (4). De esta forma, el vector completo G se relaciona mediante el modelo estadístico f_{mod} con cada vector S , de acuerdo a

$$G = f_{\text{mod}}(S) \quad (6)$$

- *Método VRT*

A causa de que el método SR está basado en la solución del problema inverso de RS, el cual es usualmente un problema “*ill-posed*” [Parker, 1994], este método tiene características que devienen en amplificación de errores, ambigüedades, etc. [Eyre et al. 1989]. Como consecuencia, mediciones remotas de alta calidad pueden resultar en valores de baja calidad de las variables geofísicas de interés. Este inconveniente puede eliminarse, o reducirse, usando las técnicas de inversión propias del método VRT, a través de la directa asimilación de mediciones de diferentes sensores remotos ([Derber, 1992], [Derber et al. 1998], [Parrish 1992], [Phalippou, 1996], [Prigent et al. 1997]). La Figura 1 muestra cómo el método VRT o de asimilación directa de datos satelitales genera los valores de las variables geofísicas. En la misma figura se observa que la función FM se emplea para *simular* los valores de datos satelitales S a partir de valores de variables geofísicas G , obtenidos estos últimos en forma complementaria por el método SR o por mediciones directas en tierra o en la superficie del océano. Finalmente el sistema completo de valores de variables geofísicas buscado, se obtiene a partir de la asimilación del banco de vectores S con técnicas de inversión multivariada similares a las definidas por las Ecs. (3) y (4), [Parrish, 1992].

Aplicación de redes neuronales a los problemas directo e inverso en RS con sensores satelitales

Desde el punto de vista matemático, las funciones FM, Ec. (2) y TF, Ec. (1), son mapas *continuos* entre los dos vectores S y G . Aun cuando el mapa generado por la Ec. (1) no sea único (dado que el problema planteado en este caso es *ill-posed*), el mapa generado multivaluado siempre se puede considerar como una colección de mapas continuos univaluados [Parker, 1994]. Dada la continuidad de estos mapas múltiples no lineales, las *redes neuronales en capas* pueden relevarlos siempre que la arquitectura de la red sea lo suficientemente densa ([Attali et al., 1997], [Chen et al. 1995a,b], [Cybenko, 1989], [Funachashi, 1989], [Hornik, 1991]). Además de las ventajas prácticas en la implementación de redes en capas para emular las funciones FM y TF tales como la velocidad computacional, exactitud y robustez [Kerlirzin et al., 1995], se agrega la facilidad y flexibilidad para incorporar, en una red ya construida, cualquier variable geofísica cuya influencia en las mediciones satelitales sea bien conocida, a pesar de que esta variable no aparezca en la FM original y también, cualquier otra información adicional. Esto puede mejorar la exactitud de la FM e inclusive ayudar a *regularizar* el problema inverso cuando se implementa una red en capas para modelizar TF empírica (Ecs. (5) o (6)) [Aires et al., 2002].

- *Redes Neuronales para modelizar FM*

Las funciones FM son comúnmente complicadas debido a la complejidad de las teorías físicas en las que están basadas, como la teoría de transferencia radiativa. Esto implica que la dependencia de las mediciones satelitales de las variables geofísicas sobre las que opera FM, sea complicada y presente diferentes tipos de comportamiento no lineal [Krasnopol'sky et al., 2013]. En los métodos SR y VRT descritos en la sección anterior, FM y su Jacobiano son calculados muchas veces en forma iterativa para cada vector S de datos satelitales. Esto produce un proceso de inversión que consume mucho tiempo computacional, que lo hace no apto para aplicaciones que emplean variables geofísicas en tiempo real. Para estas aplicaciones se necesitan versiones de FM rápidas y exactas, que pueden implementarse con redes neuronales en capas, por las razones descritas más arriba. Más aun, la red provee en tiempo real la matriz Jacobiana de FM, prácticamente sin esfuerzo computacional extra [Krasnopol'sky et al., 2013].

Para desarrollar una red que aproxime a FM debe crearse un conjunto de entrenamiento de N pares correspondientes $\{G, S\}$. Si ya existe un modelo FM basado físicamente, puede emplearse para generar el conjunto de entrenamiento; sino éste puede construirse con datos empíricos.

- *Redes Neuronales para modelizar TF*

Además de las complicaciones relativas a las funciones FM (complejidad, no linealidad, etc), los algoritmos de inversión exhiben problemas adicionales debido a que solucionan el problema inverso en RS, que es un problema *ill-posed*. Es por ello que las herramientas matemáticas que permitan desarrollar algoritmos de inversión deben ser exactas y robustas (es decir, estables). Nuevamente, las redes neuronales en capas, bien diseñadas y entrenadas, cumplen estas condiciones y son rápidas y flexibles para “mapear” el espacio continuo y no lineal de soluciones G del problema inverso, constituyendo un modelo eficiente de algoritmo de inversión multivariado.

Para su aplicación en el problema de inversión multivariada, las redes neuronales pueden emplearse en los dos procedimientos en que puede implementarse el método SR y que son descritos en la sección precedente: a) en algoritmos de inversión “físicamente fundamentados”, Ecs. (3) y (4), que emulan el complejo y lento modelo FM basado en primeros principios y su Jacobiano; de esta manera, se acelera el proceso local de inversión y b) en procesos de inversión global multivariada con una TF empírica explícita, Ecs. (5) o (6), donde directamente los datos satelitales

alimentan la entrada de una red neuronal en capas y los valores de las variables geofísicas son las salidas de la red. De esta manera, la red neuronal provee una forma explícita de algoritmo TF; es decir, su matriz de pesos, obtenida luego de su entrenamiento, que soluciona el problema inverso de RS.

Para entrenar la red, como en el caso de la emulación de FM, se debe tener un conjunto de entrenamiento constituido por los N pares $\{G, S\}$, para los cuales también, los datos pueden ser simulados o empíricos [Krasnopolsky et al., 2003].

- *El control de la capacidad de generalización*

La capacidad de *generalización* de una red es la propiedad de reproducir con certeza el mapa multivariado no lineal, que la red aprende a relevar durante el entrenamiento supervisado, cuando se le presentan datos reales *que no fueron incorporados durante su aprendizaje* [Rumelhart et al., 1986a]. En el entrenamiento de la red, para resolver el *bias- variance tradeoff* [Tsonis et al., 1992], distintas técnicas de validación se emplean para limitar el aprendizaje del ruido que portan los datos de entrada, con el objetivo de optimizar su capacidad de generalización. En todas ellas se reserva un conjunto de datos (conjunto de datos de validación) que no se emplean para cambiar la matriz de pesos de la red y con los cuales se chequea periódicamente la salida de la misma, a medida que ésta aprende a relacionar los pares de conjuntos de datos de entrada-salida durante su entrenamiento (conjunto de datos de entrenamiento) ([Rumelhart, 1986a], [Tsonis et al., 1992], [Bishop, 1995], [Rojas, 1996]).

Cuando una red neuronal se entrena para emular la función TF en la inversión global multivariada, los datos del conjunto de entrenamiento que constituyen las entradas de la red en capas (simulados por un modelo FM de primeros principios o por mediciones remotas) cubren un cierto subespacio (*manifold*) S_T del espacio de las fases completo S . Una vez que la red ya entrenada se emplea para emular TF, Ec. (1), los valores reales provenientes de mediciones en RS y que alimentan a las neuronas de entrada de la red, pueden no yacer en el espacio S_T de baja dimensionalidad de datos simulados por el modelo FM y, por lo tanto, obligar a la red a extrapolar, con salidas que pueden ser impredecibles. Las razones de las diferencias entre los datos reales de entrada y los datos simulados para el entrenamiento son simplificaciones hechas durante la construcción del modelo FM, que desprecian la natural variabilidad de las variables geofísicas elegidas para construir el modelo FM y, por otro lado, errores en las mediciones de las señales satelitales, no tenidos en cuenta durante la generación de los datos de entrenamiento. En el caso que se empleen datos reales, durante el entrenamiento, eventos extremos (que producen los valores más altos y más bajos de las variables geofísicas) usualmente no son suficientemente representados en el intervalo de entrenamiento, pues tienen muy baja frecuencia de ocurrencia en la Naturaleza [Parodi et al., 2006]. Puede ocurrir, entonces, que en la etapa de inversión implementada con una red entrenada para proveer la función TS explícitamente, los datos reales obliguen a la red a extrapolar. El error resultante de tal extrapolación se incrementa con la distancia del punto de entrada al *manifold* S_T y también depende de la orientación del vector de entrada respecto a S_T . Para mitigar este efecto y poder cubrir un subespacio más grande dentro del espacio S de entrada puede ser útil, como conjunto de entrenamiento, la mezcla de datos simulados con un modelo FM y datos empíricos bien muestreados, junto con un aumento de la cantidad de neuronas y de capas ocultas, controlando siempre con técnicas de validación el nivel de ruido aprendido [Krasnopolsky et al., 2013]

Comparación entre la performance de redes neuronales y otros algoritmos aplicados a los problemas directo e inverso en RS

Como ejemplo de las aplicaciones de redes neuronales en capas a la resolución de los problemas directo e inverso en *remote sensing*, se presenta primero la aplicación de una red neuronal para modelizar empíricamente FM. La relación que mapea la red OMBFM1 de la Figura 2 es entre el vector G de cuatro componentes: velocidad del viento W , columna de vapor de agua V , columna de agua líquida L y temperatura superficial del mar SST ; las cuales son las principales variables geofísicas que influyen las temperaturas de brillo medidas por el sensor remoto satelital SSM/I (*Special Sensor Microwave Imager*. Este instrumento, a bordo de la serie de satélites DMSP en órbita polar, recibe radiación de microondas proveniente de la superficie oceánica) y el vector S constituido por cinco temperaturas de brillo (*brightness temperature*, BT): T19V, T19H, T22V, T37V, T37H (TXXY significa XX frecuencia del canal en GHz, Y polarización horizontal o vertical). Los algoritmos referenciados en la Tabla 4 son FM basados en primeros principios. La red OMBFM1 [Krasnopolsky, 1997], que implementa el modelo empírico SSM/I FM, tiene 4 neuronas de entrada, una capa oculta con 12 neuronas, cinco salidas no lineales y 20 salidas auxiliares con las derivadas de las salidas respecto a las entradas. [Krasnopolsky et al., 2003].

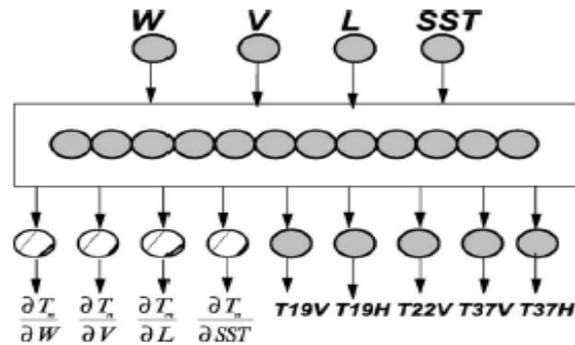


Figura 2. Red neuronal en capas OMBFM1 [Krasnopolsky et al., 2003].

Tabla 4. Comparación entre algoritmos basados en la teoría de transferencia radiativa (PB, Physically Based) y la red neuronal OMBFM1 (NN, Neural Network) La performance es medida por el error cuadrático medio (RMSE) de la temperatura de brillo (BT, en K) en condiciones de cielo claro. Los valores entre paréntesis corresponden a cielo nublado [Krasnopolsky et al., 2003].

Author	Type	Inputs	BT RMS Error (K)	
			Vertical	Horizontal
Petty and Katsaros (1992)	PB	$W, V, L, SST, \theta^{a}, P_0^{b}, HWV^{c}, ZCLD^{d}, T_s^{e}, G^{f}$	1.9 (2.3)	3.3 (4.3)
Wentz (1997)	PB	W, V, L, SST, θ^{a}	2.3 (2.8)	3.4 (5.1)
Krasnopolsky (1997)	NN, emp.	W, V, L, SST	1.5 (1.7)	3.0 (3.4)

^a θ , incidence angle.
^b P_0 , surface pressure.
^c HWV , vapor scale height.
^d $ZCLD$, cloud height.
^e T_s , effective surface temperature.
^f G , lapse rate.

A continuación se presenta como segundo ejemplo la aplicación de una red neuronal como modelo empírico TF multivariado, solución del problema inverso en RS para el mismo sensor SSM/I. La red OMBNN3 de la Figura 3 mapea el espacio definido por el vector de entrada S , que contiene las cinco temperaturas de brillo que son las salidas principales de la red OMBFM1 del ejemplo anterior y por el vector de salida G , cuyas componentes corresponden a la entrada de la red OMBFM1. Los algoritmos que compiten con la red OMBNN3 son referenciados y sus performances informadas en la Tabla 5. Todos estos algoritmos son univaluados, pues sólo recuperan la variable velocidad del viento, W ; algunas de estas técnicas son empíricas (regresiones) y otras están fundamentadas físicamente [Krasnopolsky et al., 2003].

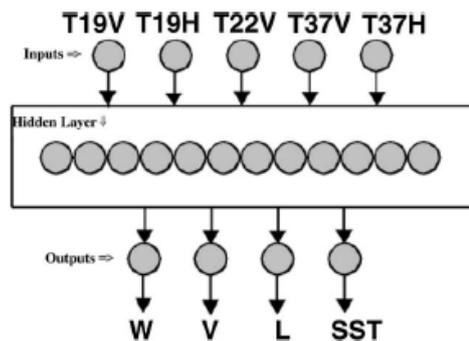


Figura 3. Red neuronal en capas OMBNN3 [Krasnopolsky et al., 2003].

Tabla 5. Comparación entre algoritmos inversos para recuperar la velocidad del viento a partir de mediciones con el sensor SSM/I y la red neuronal OMBNN3. La performance es medida por el error cuadrático medio (RMSE) de la velocidad del viento (W , en m/s) en condiciones de cielo claro. Los valores entre paréntesis corresponden a cielo nublado [Krasnopolsky et al., 2003].

Algorithm	Method	Bias	Total RMSE	$W > 15$ m/s RMSE
GSW ^a	Multiple linear regression	-0.2 (-0.5)	1.8 (2.1)	(2.7)
GSWP ^b	Generalized linear regression	-0.1 (-0.3)	1.7 (1.9)	(2.6)
GS ^c	Nonlinear regression	0.5 (0.7)	1.8 (2.5)	(2.7)
Wentz ^d	Physically based	0.1 (-0.1)	1.7 (2.1)	(2.6)
OMBNN3 ^e	NN	-0.1 (-0.2)	1.5 (1.7)	(2.3)

^a Goodberlet et al. (1989).

^b Petty (1993).

^c Goodberlet and Swift (1992).

^d Wentz (1997).

^e Krasnopolsky et al., (1996, 1999).

Conclusiones

En el actual marco de intervención del Ser Humano sobre su entorno natural, el cuidado del medioambiente del cual el Hombre forma parte es uno de los mayores compromisos y desafíos, que implica remediar los daños ya producidos y prever anticipadamente las consecuencias de sus acciones. Para ello necesita de dos herramientas fundamentales: mediciones confiables de cada parámetro de interés ambiental y un método apropiado de análisis de datos, que le permita obtener conclusiones válidas al momento de tomar decisiones. A tal efecto, este trabajo tiene el propósito de recopilar, a modo de revisión, los antecedentes disponibles sobre aplicaciones de Redes Neuronales Artificiales como método de análisis de datos medioambientales, enfatizando como ejemplo su aplicación a datos obtenidos por sensado remoto satelital.

Los dos ejemplos de aplicación de redes neuronales a *remote sensing*, descritos en la Sección 4.3, señalan que las redes neuronales en capas son una apropiada y eficiente herramienta para resolver los problemas directos e inversos de procesamiento de datos satelitales en el campo de RS.

En nuestra Facultad de Química e Ingeniería de UCA – Rosario, hay importantes antecedentes de aplicaciones de RNA en casos de variables naturales específicas, y este primer año de desarrollo de nuestro proyecto de investigación aplicado a temas de Ingeniería Ambiental y de Impacto Ambiental encuentra un punto en común de ambos temas. La incumbencia directa del tema de investigación en el ámbito de las carreras de grado y posgrado de nuestra Facultad facilita la aproximación de estudiantes a participar conjuntamente. En especial, estamos destinando un significativo esfuerzo de nuestro proyecto a encauzar las tesis de investigación para el egreso de los profesionales que en importante número se encuentran cursando la Maestría en Medioambiente y Desarrollo Sustentable durante el periodo 2014-2015.

Referencias

- Alishouse, J. C. et al. (1990) Determination of oceanic total precipitable water from the SSM/I. IEEE Transactions on Geoscience and RemoteSensing, GE, 23, pp 811-816.
- Aires F. et al. (2002) A regularized neural net approach for retrieval of atmospheric and surface temperature with the IASI instrument. Journal of Applied Meteorology, 41, pp 144-159.
- Arboleda González, J. (2008) Manual para la evaluación de impacto ambiental de proyectos, obras o actividades, Medellín, Colombia.
http://evaluaciondelimpactoambiental.bligoo.com.co/media/users/20/1033390/files/255491/1_Manual_EIA.pdf
- Attali J.-G., Page's G. (1997) Approximation of functions by a multilayer perceptron: a new approach. Neural Networks, 10, pp 1069-1081
- Bishop, C. M. (1995) Neural Networks for Pattern Recognition. New York: Oxford University Press.
- Calvo R. A., Ceccatto H. A., Piacentini R. D.. (1995) Neural network prediction of solar activity. Astrophys. J., Vol. 444, pp 916-921.
- Canter L., Sadler B. (1997) Tool Kit for Effective EIA Practice. International Association For Impact Assessment.
<http://www.iaia.org/publicdocuments/EIA/SRPEASEIS01.pdf>

- Cede A., Luccini E., Nuñez L., Piacentini R., Blumthaler M. and Herman J. (2004) TOMS-derived erythemal irradiance versus measurements at the stations of the Argentine UV Monitoring Network. *Journal of Geophysical Research*, 109(D08109), doi:10.1029/2004JD004519.
- Chen T., Chen H. (1995a) Approximation capability to functions of several variables, nonlinear functionals, and operators by radial basis function neural networks. *Neural Networks*, 6, pp 904-910.
- Chen T., Chen H. (1995b) Universal approximation to nonlinear operators by neural networks with arbitrary activation function and its application to dynamical systems. *Neural Networks*, 6, pp 911-917.
- Conesa Fernández-Vítora, V. (1995) Guía metodológica para la evaluación de impacto ambiental. Ediciones Mundi-Prensa, Madrid.
- Cybenko G. (1989) Approximation by superposition of sigmoidal functions. *Mathematics of Control, Signals and Systems*, 2, pp 303-314.
- Derber J. C., Wu W.-S. (1998) The use of TOVS cloud-cleared radiances in the NCEP SSI analysis system. *Monthly Weather Reviews*, 126, pp 2287-2299.
- Eyre J. R., Lorenc A. C. (1989) Direct use of satellite sounding radiances in numerical weather prediction. *Meteorology Magazine*, 118, pp 13-16.
- Elman, J. L. (1990) Finding structure in time. *Cognitive Science*, 14, pp 179-211.
- Espinoza G. (2007) Gestión y fundamentos de evaluación de impacto ambiental. Banco Interamericano de Desarrollo, Centro de Estudios para el Desarrollo, Santiago, Chile.
- Funahashi K. (1989) On the approximate realization of continuous mappings by neural networks. *Neural Networks*, 2, pp 183-192.
- Gómez Orea, D. (1988) Evaluación del impacto ambiental de proyectos agrarios. Estudios monográficos N° 6, Ministerio de Agricultura, Pesca y Alimentación, Madrid, España.
- Goodberlet M. A., Swift C. T., Wilkerson J. C. (1989) Remote sensing of ocean surface winds with the special sensor microwave imager. *Journal of Geophysical Research*, 94, pp 14547-14555.
- Hadamard J. (1902) Sur les problèmes aux dérivées partielles et leur signification physique. *Princeton University Bulletin*, Vol. 13, pp 49-52.
- Hornik K. (1991) Approximation capabilities of multilayer feedforward network. *Neural Networks*, 4, pp 251-257.
- Kerlirzin P., Re'fre'gier P. (1995) Theoretical investigation of the robustness of multilayer perceptrons: analysis of the linear case and extension to nonlinear networks. *IEEE Transactions on neural networks*, 6, pp 560-571.
- Krasnopolsky V. M., Gemmill W. H., Breaker, L. C. (1999) A multiparameter empirical ocean algorithm for SSM/I retrievals. *Canadian Journal of Remote Sensing*, 25, pp 486-503.
- Krasnopolsky V. M., Gemmill W. H., Breaker L. C. (2000) A neural network multiparameter algorithm SSM/I ocean retrievals: comparisons and validations. *Remote Sensing of Environment*, 73, pp 133-142.
- Krasnopolsky V. M., Schiller H. (2003) Some neural network applications in environmental sciences. Part I: forward and inverse problems in geophysical remote measurements. *Neural Networks*, Vol. 16, Issues 3-4, pp 321-334. <http://polars.ncep.noaa.gov/mmab/papers/tn225/MMAB225.pdf>
- Krasnopolsky V. M. (2013) The Application of Neural Networks in the Earth System Sciences. *Neural Networks Emulations for Complex Multidimensional Mappings*. Atmospheric and Oceanographic Sciences Library. Vol. 46, ISBN: 978-94-007-6072-1 (Print) 978-94-007-6073-8 (Online) Springer.
- Luccini E., Cede A., Piacentini R., Villanueva C. and Canziani P. (2006) Ultraviolet climatology over Argentina. *Journal of Geophysical Research*, 111(D17312), doi:10.1029/2005JD006580.
- Parker R. L. (1994) *Geophysical inverse theory*. Princeton University Press, Princeton.
- Parodi M. A., Ceccatto H. A. and Piacentini R. D. (2006) Neural network analysis of the effect of Mt. Pinatubo eruption on the Southern Hemisphere high latitude ozone. *WSEAS Transactions On Information Science & Applications*, 3, pp 588-594. http://www.conicet.gov.ar/new_scp/detalle.php?keywords=&id=21385&articulos=yes&detalles=yes&art_id=62517
- Parodi M. A., Ceccatto H. A., Navone H. D. and Piacentini R. D. (1997) Aplicación de las redes neuronales al análisis de la evolución de la capa de ozono entre 30°S y 40°S. *Energías Renovables y Medio Ambiente*, 3, pp 5-12.
- Parrish D. F., Derber J. C. (1992) The national meteorological center's spectral statistical interpolation analysis system. *Monthly Weather Reviews*, 120, pp 1747-1763.
- Petty G. W. (1993) A comparison of SSM/I algorithms for the estimation of surface wind. *Proceedings Shared Processing Network DMSP SSM/I Algorithm Symposium*, pp 8-10.
- Phalippou L. (1996) Variational retrieval of humidity profile, wind speed and cloud liquid-water path with the SSM/I: potential for numerical weather prediction. *Quarterly Journal of Royal Meteorological Society*, pp122327-122355.
- Pitari G., Rizi V. (1993) An estimate of the chemical and radiative perturbation of stratospheric ozone following the eruption of Mt. Pinatubo. *J. Atmos. Sci.*, 50, pp 3260-3276.
- Prigent C., Phalippou L., English, S. (1997) Variational inversion of the ssm/i observations during the ASTEX campaign. *Journal of Applied Meteorology*, 36, pp 493-508.
- Rojas R., (1996) *Neural Networks - A Systematic Introduction*. Springer-Verlag, Berlin, New York. <http://page.mi.fu-berlin.de/rojas/neural/>
- Ronco, E., Gawthrop, P. (1995) Modular neural networks: a state of art. Technical Report CS-95026, University of Glasgow.

- Rumelhart, D. E., Durbin R., Golden R., Chauvin Y. (1993) "Backpropagation: The basic Theory". In Backpropagation: Theory, Architectures and Applications, edited by Y. Chauvin and D. E. Rumelhart. Hillsdale, NJ: Lawrence Erlbaum.
- Rumelhart, D. E., Hinton G. E., Williams R. J. (1986a) "Learning Internal Representations by Error Propagation". In Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1: Foundations, edited by D. E. Rumelhart and J. L. McClelland, Cambridge, MA: MIT Press/Bradford Books, pp 318-362
- Schmidt, A., Bandar, Z. (1998) Modularity, a concept for new neural network architectures. IASTED International Conference on Computer Systems and Applications (CSA'98) 1998 in Irbid/Jordan, pp 26-29.
- Stoffelen A., Anderson D. (1997) Scatterometer Data interpretation: estimation and validation of the transfer function CMOD4. Journal of Geophysical Research, 102, pp 5767-5780.
- Tsonis A. A., Elsner J. B. (1992) Nonlinear Prediction as a Way of Distinguishing Chaos from Random Fractal Sequences. Nature 359, pp 217-220.
- Verdes P., Parodi M. A., Granitto P., Navone H. D., Piacentini R. D. and Ceccatto H. A. (2000) Predictions of the maximum amplitude for solar cycle 23 and its subsequent behavior using nonlinear methods. Solar Physics, Vol. 191, Issue 2, pp. 87-93.
<http://link.springer.com/article/10.1023%2FA%3A1005202814071>
- Weigend A. S., Gershenfeld, N. A. (1994) Time Series Prediction: Forecasting the future and understanding the past. Proceedings of the NATO Advanced Research Workshop on Comparative Time Series Analysis, Santa Fe, New Mexico.
- Wentz F. J. (1997) A ell-calibrated ocean algorithm for special sensor microwave/imager. Journal of Geophysical Research, 102, pp 8703-8718.