

APLICACIÓN DEL MODELO PERCEPTRÓN MULTICAPA PARA EL PRONÓSTICO DE INUNDACIONES POR PENETRACIONES DEL MAR EN LA COSTA NORTE OCCIDENTAL DE CUBA

Lic. Dahiana Torres Pablos

Centro de Meteorología Marina. Instituto de Meteorología,
Carretera del Asilo s/n. Loma de Casablanca, Regla, Ciudad de La Habana,
Cuba, Teléf.: 868-6519, E-mail: dahiana.torres@insmet.cu

RESUMEN

Las inundaciones por penetraciones del mar en la costa Norte de la región occidental de Cuba, son producidas por áreas formadoras de oleaje asociados a fenómenos meteorológicos peligrosos que transitan por el Golfo de México como bajas extratropicales, frentes fríos y huracanes. Dada una situación meteorológica peligrosa para esta área, se quiere predecir si se producirán o no inundaciones costeras por penetraciones del mar, a partir del análisis de los datos de los fenómenos meteorológicos anteriores, teniendo en cuenta el conjunto de valores de presión para la rejilla que abarca el Golfo de México.

En la presente investigación se aplicó el modelo de Redes Neuronales Artificiales con aprendizaje supervisado: Perceptrón Multicapa, el cual establece una clasificación para la situación meteorológica de pronóstico actual asociado a bajas extratropicales y frentes fríos, empleando como herramienta la plataforma Weka. Se comprobó la efectividad de esta red para el pronóstico de inundaciones costeras por penetraciones del mar, determinando los valores del conjunto de parámetros correspondientes a este modelo.

Palabras clave: inundaciones costeras, pronóstico, clasificación, Perceptrón Multicapa.

APPLICATION OF MULTILAYER PERCEPTRON'S MODEL FOR FLOOD FORECASTING BY SEA PENETRATIONS ON THE NORTHWEST COAST OF CUBA

ABSTRACT

Flooding by sea penetrations in the northern coast of western Cuba, are produced by waves forming areas associated with dangerous weather phenomenon transiting the Gulf of Mexico, as an extratropical low, cold fronts and hurricanes. Given a dangerous weather situation for this area, we want to predict whether or not there will be coastal flooding by sea penetrations, from analysis of data from past weather events, taking into account all pressure values for the grid covers the Gulf of Mexico.

In the present study applied the model of Artificial Neural Networks with Supervised Learning: Multilayer Perceptron, which provides a classification for the current forecast weather conditions associated with extratropical low and cold fronts, using as a tool Weka platform. It proved the effectiveness of this network for the prediction of coastal flooding by sea penetrations, determining the values of all parameters of this model.

Key words: Flooding by sea penetrations, forecast, classification, Multilayer Perceptrón.

INTRODUCCIÓN

Uno de los objetivos propuestos por el Centro de Meteorología Marina (CMM), es la realización diaria de un pronóstico meteorológico marino el cual cubre las aguas territoriales del país y mares adyacentes. El personal de este centro utilizará estas observaciones íntegramente para facilitar un servicio meteorológico adecuado a todas las formas de actividades marinas. (Hernández, 2007)

Las inundaciones costeras por penetraciones del mar es uno de los fenómenos más peligrosos de la naturaleza. En la década de los años 80 del siglo pasado, comienzan a emplearse en Cuba las primeras técnicas para su pronóstico, (Hernández, 2007) que se basaban en la solución de relaciones empíricas que relacionaban la velocidad, alcance y persistencia del viento con las características de las olas. A partir de la solución de estas relaciones se obtuvieron resultados importantes acerca del comportamiento del estado del mar en presencia de condiciones meteorológicas extremas.

Para pronosticar específicamente las inundaciones costeras por penetraciones del mar, solo se ha empleado el método de análogos, que se basa en la comparación de situaciones meteorológicas producidas con anterioridad con la situación de pronóstico actual, en la que resulta difícil la memorización de todas las situaciones sinópticas ocurridas. De esta forma se podrá predecir la ocurrencia o no de inundación costera por penetraciones del mar en un sector de interés.

Para mejorar las técnicas tradicionales de pronóstico de inundaciones se ha propuesto la aplicación de las Redes Neuronales Artificiales (RNA) como modelos entrenados para realizar conexiones entre los valores pasados y presentes, aprendiendo de su error de pronóstico, y extraer estructuras y relaciones escondidas que gobiernan el sistema de información (Jalil, 2006), a su vez que se almacena esta clasificación. Estas redes han tenido una mayor atención en las recientes investigaciones para la realización de los pronósticos marinos. (Organ, 2004)

Se empleó el modelo Perceptrón Multicapa (MLP) como una RNA clasificadora para realizar el pronóstico de inundaciones costeras por penetraciones del mar en la costa norte de la región occidental de Cuba, determinando la clasificación de las situaciones meteorológicas de pronóstico actual.

MATERIALES Y MÉTODOS

Empleo del método de análogos para predecir la ocurrencia de inundaciones costeras por penetraciones del mar

Para realizar el pronóstico de inundaciones costeras por penetraciones del mar (Petterssen, 1941) se emplea el método de análogos. Mediante este método se examina el escenario del pronóstico actual (comportamiento de las variables meteorológicas), y se compara con algún escenario meteorológico pasado muy similar, es decir, un análogo. Para utilizar este método es necesario tener en cuenta todos los fenómenos meteorológicos que provocaron las inundaciones costeras por penetraciones del mar en el tramo costero Punta Gobernadora – Punta Hicacos.

La complejidad de este método deviene en que es implícitamente imposible encontrar un análogo perfecto, (Petterssen, 1941) ya que todas las variables del tiempo raramente se repiten donde ellas fueron observadas

anteriormente. Por esta razón, los datos obtenidos de las situaciones meteorológicas anteriores se basaron en la configuración básica de la rejilla que abarca las longitudes de 98-70 grados oeste y las latitudes 35-17 grados norte.

El Perceptrón Multicapa como modelo clasificador

La clasificación incluye un amplio desarrollo de los enfoques teóricos de decisión. Dado un número discreto de clases que pueden ser mutuamente excluyentes, el objetivo es determinar la pertenencia de un ejemplo de entrada a una de las clases. Si la respuesta se encuentra representada por variables nominales, esto indica un problema de clasificación, donde los valores nominales corresponden a las diferentes clases. (Slobodan, 2002)

Una herramienta empleada actualmente para la clasificación son las RNA, las cuales se ha demostrado que pueden comportarse, al menos, igual que los métodos estadísticos tradicionales de pronóstico. (Organ, 2004)

El Perceptrón Multicapa tienen como objetivo la categorización o clasificación de forma supervisada de los datos, siendo una de las redes más utilizadas para la clasificación. (Couchman, 2003) Para el presente estudio se ha utilizado esta red aplicado a la clasificación binaria.

Utilizando el algoritmo de aprendizaje supervisado Backpropagation, la red aprende la relación entre los ejemplos de entrada, valores de presión de la rejilla, y su correspondiente clase, definida por si produjo o no inundación costera (fase de entrenamiento), para luego poder categorizar un ejemplo de entrada del cual se desconoce su salida (fase de aprendizaje).

Para el estudio se tomaron 19 muestras de frentes fríos y 10 muestras de bajas extratropicales, en un período que abarca desde 1977-2001. (Tabla 1. Torres, 2008) Se exceptúa del mismo los fenómenos de huracanes. Los ejemplos que no provocaron inundación costera por penetraciones del mar, se seleccionaron por su similitud a los que pertenecen a la otra clase. Para esta clase se cuenta con 10 situaciones meteorológicas. (Tabla 2. Torres, 2008)

Para la clasificación se requiere de la selección de parámetros sensibles a la selección según el problema a resolver, por esta razón se consideran diferentes vectores de valores iniciales, seleccionando aquel que converja al mínimo valor de la función objetivo. (Jalil, 2006) Estos parámetros son: cantidad de capas, cantidad de neuronas en cada capa, cantidad de épocas, valor de la velocidad de aprendizaje, valor del momentum, utilización de la degradación de la velocidad de aprendizaje (decay learning).

La herramienta Weka

Para realizar la clasificación de las inundaciones costeras por penetraciones del mar se empleó la herramienta Weka. Es un conjunto de librerías implementadas en Java para la extracción de conocimientos desde bases de datos (licencia GPL). (Hernández, 2006) Incluye diferentes características que pueden ser aplicadas sobre los datos, como herramientas para minería de datos, manipulación y visualización de los mismos, entre otras. (Salas, 2002)

Para confeccionar el archivo de datos de entrada que requiere esta herramienta, se ha realizado la implementación de funciones que permiten automatizar el proceso de obtención de los datos de presión a partir del archivo GRIB, insertando en este fichero los valores procesados y su clase asociada.

RESULTADOS

Una vez elegido el MLP en la herramienta Weka para la clasificación de los datos y los parámetros que intervienen en esta red, antes de realizar la fase de entrenamiento, se escogerá el método utilizado para la evaluación de este algoritmo. Los métodos escogidos para el estudio son: uso del conjunto de entrenamiento (Using training set) , (García, 2006) validación cruzada (Cross- validation), (García, 2006) porcentaje dividido (Percentage Split) . (Hernández, 2006)

Cuando se realiza la evaluación de los datos según el método de evaluación escogido se presentan los siguientes datos estadísticos: (Villena, 2003) instancias bien clasificadas (Bien %), instancias mal clasificadas (Mal %), estadísticas Kappa (Ks), error medio absoluto (Mae), raíz del error cuadrático medio (Rmse), error relativo (Rae %), raíz del error cuadrático relativo (Rrse %).

A continuación (Tabla 1) se muestran todos los resultados obtenidos de las pruebas realizadas con los tres métodos de evaluación sobre la misma arquitectura: tres capas, con 96 neuronas en la capa de entrada correspondientes a los atributos, 50 neuronas en la capa oculta y dos neuronas en la capa de salida correspondiente a las dos clases.

Tabla 1. Tablas de pruebas por métodos de evaluación. A) Using training set. B) Cross- Validation. C) Percentage split

A	Parámetros de la red MLP					Medidas de evaluación del algoritmo de aprendizaje								
	Nº	dL	Lr	M	Na	E	Bien	Mal	Ks	Mae	Rmse	Rae	Rrse	CI
	1	False	0.5	0.4	True	500	37	0	1	0.004	0.008	1.25	0.97	37
	2	False	0.5	0.2	True	500	37	0	1	0.004	0.009	1.40	2.25	37
	3	False	0.8	0.4	True	500	37	0	1	0.003	0.006	0.96	1.52	37
	4	False	0.8	0.6	True	500	37	0	1	0.002	0.005	0.77	1.23	37
	5	False	0.9	0.6	True	500	37	0	1	0.002	0.004	0.72	1.14	37
	6	False	0.9	0.9	True	500	29	8	0	0.21	0.46	62.27	112.8	37
	7	False	0.9	0.8	True	500	37	0	1	0.009	0.003	0.55	0.93	37
	8	False	0.9	0.8	True	1000	37	0	1	0.001	0.002	0.38	0.64	37
	9	False	0.3	0.1	True	1000	37	0	1	0.004	0.009	1.35	2.18	37
	10	False	0.9	0.1	True	1000	37	0	1	0.002	0.004	0.74	1.18	37

Nº	Parámetros de la red MLP					Medidas de evaluación del algoritmo de aprendizaje							
	dL	Lr	M	Na	E	Bien	Mal	Ks	Mae	Rmse	Rae	Rrse	CI
1	False	0.3	0.2	True	500	33	4	0.70	0.13	0.31	38.13	76.99	37
2	True	0.3	0.2	True	500	29	8	0	0.33	0.39	95.58	96.19	37
3	True	0.3	0.2	True	1000	28	9	-.05	0.33	0.39	94.96	95.54	37
4	False	0.3	0.2	True	1000	33	4	0.70	0.13	0.31	37.72	77.27	37
5	False	0.3	0.2	False	500	29	8	0	0.30	0.42	86.97	102.1	37
6	False	0.5	0.2	True	500	33	4	0.70	0.13	0.31	37.64	77.11	37
7	False	0.3	0.5	True	500	33	4	0.70	0.13	0.31	37.36	76.68	37
8	False	0.5	0.5	True	500	32	5	0.61	0.13	0.31	37.40	77.23	37
9	False	0.1	0.5	True	500	33	4	0.70	0.13	0.31	38.38	76.20	37
10	False	0.5	0	True	500	33	4	0.70	0.13	0.31	37.82	77.11	37
11	False	0.5	0.1	True	500	33	4	0.70	0.13	0.31	37.78	77.14	37
12	False	0.5	0.3	True	500	33	4	0.70	0.13	0.31	37.48	77.02	37
13	False	0.5	0.4	True	500	33	4	0.70	0.13	0.31	37.30	77.05	37
14	False	0.8	0.4	True	500	32	5	0.61	0.13	0.32	38.45	78.53	37

Nº	Parámetros de la red MLP					Medidas de evaluación del algoritmo de aprendizaje							
	dL	Lr	M	Na	E	Bien	Mal	Ks	Mae	Rmse	Rae	Rrse	CI
1	False	0.9	0.8	True	1000	7	1	0	0.15	0.36	52.17	124.1	8
2	False	0.3	0.2	True	1000	7	1	0	0.17	0.37	58.61	128.95	8
3	True	0.5	0.3	True	1000	7	1	0	0.19	0.26	65.99	92.86	8
4	False	0.9	0.9	True	1000	8	0	1	0	0	0	0	8
5	False	0.9	0.3	True	1000	6	2	0	0.19	0.39	65.68	137.4	8
6	False	1.0	0.9	True	1000	8	0	1	0	0	0	0	8
7	False	1.0	1.0	True	1000	8	0	1	0	0	0	0	8
8	False	0.9	0.9	True	500	error							8
9	False	0.2	0.1	True	1000	7	1	0	0.16	0.36	56.99	127.33	8
10	False	0.8	0.9	True	1000	8	0	1	0	0	0.0004	0.0004	8

Aunque los valores de los parámetros LearningRate y momentum, en la mayoría de los casos donde se ha aplicado este algoritmo de aprendizaje, se estiman entre 0,2-0,4; es importante señalar que para algunas pruebas satisfactorias, estos parámetros alcanzaron valores de 0,8-1 para el LearningRate y para el momentum de 0,6-1.

DISCUSIÓN

Según los resultados de estas pruebas se concluyó que:

- Utilizando el método de evaluación Using training set, se validó sobre las 37 muestras. El valor promedio obtenido fue de 36,2 instancias bien clasificadas del total de muestras, clasificándose incorrectamente como promedio 0,8. Se realiza con un valor promedio del LearningRate de 0,7, lográndose un error más pequeño con el valor 0,9, el valor promedio del momentum es de 0,49. En todas las pruebas se utilizaron 1 000 épocas. Cabe destacar que si el momentum es igual al mejor valor del LearningRate se obtiene la peor clasificación.

Tabla 2. Valores de las medias y desviación estándar de las pruebas con el método de evaluación Using training set

	Bien	Mal	Ks	Mae	Rmse	Rae	Rrse
Medias	97.83	2.1	0.9	0.02	0.05	7.04	12.59
Des Est	2.52	2.52	0.31	0.06	0.14	19.40	35.24

- Utilizando el método de evaluación Validación Cruzada (Cross- Validation), se validó sobre las 37 muestras, con diez particiones (folds). El valor promedio obtenido fue de 32 instancias bien clasificadas y cinco mal clasificadas de la muestra total. Se realiza con un valor promedio del LearningRate de 0,4, el valor promedio del momentum es también de 0,4. En todas las pruebas se utilizaron 500 épocas lográndose un error más pequeño con 0,7 de LearningRate y 0,4 como valor del momentum. Utilizando 1 000 épocas se obtiene una mejor clasificación.

Tabla 3. Valores de las medias y desviación estándar de las pruebas con el método de evaluación Cross- Validation

	Bien	Mal	Ks	Mae	Rmse	Rae	Rrse
Medias	86	14	0.53	0.17	0.33	49.50	81.58
Des Est	1.81	1.81	0.30	0.08	0.03	23.38	8.99

- Utilizando el método de evaluación Percentage split tomando 20 % de los datos para la evaluación (esto equivale a tener ocho muestras para la evaluación), el valor promedio obtenido fue de 7,33 instancias bien clasificadas del total de muestras que se evaluaron, clasificando incorrectamente como promedio 0,66 muestras. Esto se logra con un valor promedio del LearningRate de 0,7 y del momentum de 0,6. La cantidad de épocas es de 1 000, ya que si se disminuye se produce un error de memoria.

Tabla 4. Valores de las medias y desviación estándar de las pruebas con el método de evaluación Percentage split

	Bien	Mal	Ks	Mae	Rmse	Rae	Rrse
Medias	91.63	8.38	0.44	0.09	0.19	33.27	67.85
Des Est	0.70	0.70	0.52	0.19	31.84	31.84	65.49

Para obtener una mejor clasificación en todas las pruebas realizadas con esta topología, todos los atributos de entrada fueron normalizados y no se utilizó el decay learning.

No se realizaron pruebas utilizando otra capa oculta ya que se concluyó que utilizando una sola capa el problema puede ser representado por polígonos separables. El comportamiento del algoritmo de aprendizaje fue satisfactorio en cuanto a la predicción de los patrones que se utilizaron para la evaluación, logrando la capacidad de generalizar, dado los valores obtenidos en los tres métodos de evaluación utilizados para el estudio.

CONCLUSIONES

El desarrollo de esta investigación se ha basado en modelar el problema del pronóstico de inundaciones costeras por penetraciones del mar de forma tal que se pueda brindar una solución factible a través de una herramienta computacional, que en otras áreas ha sido de gran beneficio.

Con el empleo de la herramienta Weka se ha podido comprobar la utilidad que tiene el uso de las Redes Neuronales Artificiales, específicamente el modelo Perceptrón Multicapa, para el pronóstico de inundaciones costeras por penetraciones del mar. Las clasificaciones realizadas en situaciones meteorológicas que pueden provocar este fenómeno natural, fueron en la mayoría de los casos satisfactorias para las muestras evaluadas, por lo que la aplicación de este modelo es factible para elaborar el pronóstico de inundaciones por penetraciones del mar en la costa norte de la región occidental de Cuba. Este es una herramienta que permite además que se automatice la elaboración del pronóstico marino, sin dejar la importante valoración del pronosticador con respecto a la elaboración de las predicciones.

Los valores de los parámetros que intervienen en la red MLP, que brindan mejores resultados y hacen que la red tenga un comportamiento estable por lo que logra la habilidad de generalizar fueron los siguientes:

- Cantidad de capas: 3
- LearningRate: 0,5
- Momentum: 0,6
- Cantidad de épocas: 1 000
- No se utiliza el decay learning
- Se normalizan los atributos

AGRADECIMIENTOS

A M. Sc. Reynaldo Casals Taylor (INSMET) y a Lic. Evelín Fonseca Cruz (UH) por ser guías de este trabajo.

A todos los que me brindaron su apoyo incondicional en la realización de la presente investigación.

REFERENCIAS

- Couchman, P.; F. Imbault, R. Tigreat and U. Tellechea Gorka (2003): "Classification assignment: Image processing". Tesis de maestría en Sistemas embebidos. Universidad de Heriot Watt.
- García Morate, D. (2006): "Manual de Weka", <http://metaemotion.com/diego.garcia.morate/download/weka.pdf>
- Hernández, J. y C. Ferri (2006): "Introducción al Weka". Curso de Doctorado Extracción automática de conocimiento en Bases de Datos e Ingeniería de Software. Universidad Politécnica de Valencia.
- Hernández, N. (2007): "Desarrollo del pronóstico marino en Cuba 2007. Algunas técnicas". Cuba: Centro de Meteorología Marina, Instituto de Meteorología.
- Jalil, M. y Martha Misas (2006): "Evaluación de pronósticos del tipo de cambio utilizando redes neuronales y funciones de pérdida asimétricas". Banco de la República de Colombia.
- Organ, D. (2004): "Flood Forecasting using Nonlinear Time Series Analysis". Tesis de diploma. Universidad del Sur de la Florida (USF). Departamento de Ingeniería Industrial, Estados Unidos.
- Petterssen, S. (1941): "Introduction to Meteorology". 1ra. edición. McGraw- Hill Book Company, Inc.
- Salas, R. (2002): "Robustez en Redes Neuronales Feedforward". Tesis de Maestría en Ingeniería Informática. Universidad Técnica Federico Santa María. Valparaíso, Chile.
- Slobodan, V. (2002): "Introduction to Neural Networks". Curso de primavera. www.ist.temple.edu/~vucetic/cis350spring2002.htm
- Torres, D. (2008): "Aplicación del modelo Perceptrón Multicapa para el pronóstico de inundaciones por penetraciones del mar en la costa Norte Occidental de Cuba". Tesis de Diploma. Universidad de la Habana, Cuba.
- Villena, J. (2003): "Minería de datos". Universidad Carlos III Madrid, <http://www.it.uc3m.es/jvillena/irc/practicar/03-04/18.mem.pdf>