

Redes Neuronales: Aplicación en la predicción de datos medioambientales.

WENCESLAO GONZÁLEZ MANTEIGA


Departamento de Estadística e Investigación Operativa
Universidad de Santiago de Compostela

Las Redes Neuronales


EL ORIGEN

- A **mediados de siglo** surge un movimiento científico INTERDISCIPLINAR con el objetivo de crear **inteligencia**
- **¿CÓMO?** Imitando al **cerebro humano**

LA NEURONA



Las Redes Neuronales



Distintos modos de procesar dan lugar a diferentes tipos de redes neuronales

Clasificación

↑ CONEXIONES

CONEXIONES HACIA DELANTE (FEEDFORWARD)

*CONEXIONES HACIA DELANTE Y HACIA ATRÁS
(FEEDFORWARD-FEEDBACK)*

↑ TOPOLOGÍA

EL PERCEPTRÓN


RED NEURONAL DE BASE RADIAL

↑ APRENDIZAJE

REDES ON-LINE FRENTE A REDES OFF-LINE

*APRENDIZAJE SUPERVISADO FRENTE A NO
SUPERVISADO*


Perceptrón con una Capa Oculta



$$h_j = f_h \left(\omega_{0j}^{ah} + \omega_{1j}^{ah} Z_1 + \dots + \omega_{N_I j}^{ah} Z_{N_I} \right)$$

Salida de la Red

Red Neuronal




Dimensión VC. Ejemplos

3 Sea $U = \mathbb{R}^2$ y sea C el conjunto de semiespacios abiertos

$$C = \{ax + by < c, \text{ con } a, b, c \in \mathbb{R}\}$$

C puede separar cualquier conjunto de **3** elementos no colineales, pero no puede separar ningún conjunto de **4** elementos, luego $VCD(C) = 3$

a)



b)



Dimensión VC en Redes Neuronales

PERCEPTRÓN SIMPLE

El perceptrón simple se comporta como un discriminante lineal en $\mathfrak{R}^{N_I}$

Sea $\mathcal{F} = \mathcal{P}_{\mathcal{N}_I}$ la familia de funciones asociadas al perceptrón

$$f : U = \mathfrak{R}^{N_I} \rightarrow \mathfrak{R}, \text{ tales que}$$
$$f(\mathbf{Z}) = f(Z_1, \dots, Z_{N_I}) = w_{01}^{ao} + w_{11}^{ao} Z_1 + \dots + w_{N_I 1}^{ao} Z_{N_I}$$

Esta familia está parametrizada por los vectores

$$(w_{01}^{ao}, w_{11}^{ao}, \dots, w_{N_I 1}^{ao}) \in \mathfrak{R}^{N_I} \quad \text{Luego} \quad \boxed{\dim \mathcal{P}_{\mathcal{N}_I} = VCD(\mathcal{P}_{\mathcal{N}_I}) = N_I + 1}$$

La Estadística y las Redes Neuronales

El origen de las redes neuronales, totalmente ajeno a la estadística, hizo que esta relación no fuese evidente para aquellos científicos involucrados en el estudio de las redes neuronales. Crearon con el tiempo una terminología propia que en muchos casos podemos vincular con términos estadísticos

Este paralelismo no se detiene sólo en la terminología. Existe una estrecha vinculación entre las redes neuronales y la estadística. Muchos *métodos estadísticos*, unos clásicos y otros más recientes, han sido *reescritos*, no siempre de forma consciente, como *redes neuronales*.

Veamos con más detalle el paralelismo existente entre la terminología estadística y la terminología asociada a las redes neuronales

Redes Neuronales	Estadística
CARACTERÍSTICAS	VARIABLES
INPUTS	VARIABLES INDEPENDIENTES
OUTPUTS	PREDICCIONES
VALORES OBJETIVO O DE APRENDIZAJE	VARIABLES DEPENDIENTES
ERRORES	RESIDUOS
APRENDIZAJE, ENTRENAMIENTO, AUTOORGANIZACIÓN	ESTIMACIÓN
FUNCIÓN DE ERROR, DE COSTE O DE LIAPUNOV	CRITERIO DE ESTIMACIÓN

Redes Neuronales	Estadística
PATTERNS	OBSERVACIONES
PESOS	PARÁMETROS ESTIMADOS
APRENDIZAJE SUPERVISADO	ANÁLISIS DISCRIMINANTE Y REGRESIÓN
APRENDIZAJE SIN SUPERVISIÓN	REDUCCIÓN DE LA DIMENSIÓN
APRENDIZAJE COMPETITIVO	ANÁLISIS CLUSTER
GENERALIZACIÓN	INTERPOLACIÓN, ESTRAPOLACIÓN
VALIDATION SET	MUESTRA
	POBLACIÓN

La Estadística y las Redes Neuronales


Hemos señalado que muchos métodos estadísticos pueden ser reescritos a través de alguna red neuronal.

Esto se extiende a métodos paramétricos y no paramétricos de regresión, de estimación de la función de densidad, técnicas de reducción de la dimensionalidad,...

Algunos de estos métodos son:

- ***Regresión Lineal***
- ***Regresión Polinómica***
- ***Regresión Logística***
- ***Modelos G.L.M.***
- ***Modelos G.A.M.***
- ***Regresión Projection Pursuit***
- ***Modelos G.G.A.M.***
- ***Single Index Model***
- ***Análisis Factorial***
- ***Análisis de Componentes Principales***

Regresión Polinómica



$$h_j = (z_i)^k, \text{ con } 1 \leq j \leq N_I * S = N_H$$

$$j = (i-1) * S + k, \text{ con } 1 \leq i \leq N_I, \text{ con } 1 \leq k \leq S$$

Salida de la Red

Regresión G.L.M.

LA IDEA.

La *regresión polinómica* que tratamos previamente era una generalización inmediata de la *regresión lineal*, en tanto en cuanto ésta es una regresión polinómica de grado 1.


Otro camino por el que se ha tratado de generalizar la regresión lineal consiste en *aplicarle a la combinación lineal una función determinada*. De este modo estimamos la relación entre un conjunto de variables regresoras $Z_1, Z_2, \dots, Z_{N_I}$ y una variable respuesta Y a través de una función de la forma

$$E[Y/Z_1, \dots, Z_{N_I}] = H(a + b_1 Z_1 + b_2 Z_2 + \dots + b_{N_I} Z_{N_I})$$

Siendo H una *función conocida*.

Estos modelos reciben el nombre de **Modelos Lineales Generalizados**.

Modelos Lineales Generalizados



$$o = H(\mathbf{w}^T \mathbf{Z}) = H(w_{01}^{ao} + w_{11}^{ao} Z_1 + \cdots + w_{p1}^{ao} Z_p)$$

Salida de la Red

Regresión G.G.A.M.

LA IDEA.

Consideramos la misma idea que en los G.A.M. Pero en este nuevo contexto serán desconocidas tanto la función H como las $f_1, f_2, \dots, f_{N_I}$ desconocidas.


$$E[Y/Z_1, \dots, Z_{N_I}] = H(f_1(Z_1) + f_2(Z_2) + \dots + f_{N_I}(Z_{N_I}))$$

Estos modelos reciben el nombre de ***Modelos Aditivos Generalizados Generales.***

Hemos de estimar una función, H , y sus entradas son a su vez funciones estimadas, lo que aumenta el número de capas ocultas de la red. También ahora existe un método clásico, iterativo, de estimación de la H .

Según qué red, utilicemos para las estimaciones de las funciones $f_1, f_2, \dots, f_{N_I}$ y de la H tendremos distintos modelos de redes que se adaptan a los G.G.A.M.

Modelos G.G.A.M.




h_i^1 Corresponde a la
previsión de $f_i(Z_i)$

Es una subred



$$h_1^2 = \sum_{i=1}^{N_I} h_i$$

$$h_j^3 = f_{h^3} \left(\omega_{1j}^{h_2 h_3} \cdot h_1^2 + \omega_{0j}^{h_2 h_3} \right)$$

para $j = 1, \dots, N_{H^3}$




$$Y = F(X)$$




Utilizaremos las redes
neuronales para estimar la
función F que explica Y con X

Entradas

Salidas





Topología de una RED NEURONAL

- N: dimensión del vector de entrada
- M: dimensión del vector de salida
- Fijar el n° de capas ocultas
- Fijar L: n° de nodos cada capa oculta
- Fijar las funciones de activación f_j

Salidas de la red neuronal

Dado $\mathbf{X} = (X_1, \dots, X_N)$

$$o_k^o = \theta_k^o + \sum_{j=1}^L \omega_{jk}^o f_j \left(\theta_j^h + \sum_{i=1}^N \omega_{ji}^h X_i \right)$$

$$k = 1, \dots, M$$

Las funciones de activación habituales: f_j

➤ Identidad $f(x) = x$

➤ Logística $f(x) = \frac{1}{1 + e^{-x}}$

➤ Función umbral (clasificación)

Faltan por determinar los pesos

$$\omega_{11}^h, \dots, \omega_{LN}^h, \omega_{11}^o, \dots, \omega_{ML}^o$$

y las tendencias

$$\boldsymbol{\theta}^h = (\theta_1^h, \dots, \theta_L^h) \quad \boldsymbol{\theta}^o = (\theta_1^o, \dots, \theta_M^o)$$

Los buscamos de forma que

$$o_k \approx y_k$$

$$\forall k = 1, \dots, M$$

Entrenamiento

Conjunto de entrenamiento

$$(\mathbf{X}_1, \mathbf{Y}_1), \dots, (\mathbf{X}_P, \mathbf{Y}_P)$$

Criterio de error

$$\frac{1}{2} \sum_{k=1}^M (y_k - o_k)^2$$

Buscamos los pesos que minimizan el error

Algoritmo de entrenamiento: BACKPROPAGATION

(basado en algoritmo Steepest Descent)

Este algoritmo busca, en cada iteración del entrenamiento, la dirección de máximo descenso de la función de error.

$$\left(-\frac{\partial EC}{\partial \omega_{kj}^o} \right)$$

$$\left(-\frac{\partial EC}{\partial \omega_{ji}^h} \right)$$

Y modifica los pesos de la red en esa dirección.

$$\omega_{kj}^o(p+1) = \omega_{kj}^o(p) - \eta \frac{\partial EC}{\partial \omega_{kj}^o} \omega_{kj}^o(p)$$

$$\omega_{ji}^h(p+1) = \omega_{ji}^h(p) - \eta \frac{\partial EC}{\partial \omega_{ji}^h} \omega_{ji}^h(p)$$

Pasos del Algoritmo

- 1.- Aplicar $\mathbf{X}_p = (X_{p1}, \dots, X_{pN})$ a los nodos de entrada.
- 2.- Calcular las salidas de la capa de salida:

$$O_1, \dots, O_k, \dots, O_M$$

- 3.- Calcular los errores de la capa de salida:

$$e_k = (Y_k - o_k)^2 \quad \forall k = 1, \dots, M$$

Si el error es admisible ir al paso 6.

En otro caso continuar

- 4.- Se calculan las direcciones de máximo descenso.
- 5.- Se actualizan los pesos, según las ecuaciones vistas.
- 6.- Hacer $p=p+1$. Volver al paso 1.

Algunas observaciones:

- Será necesario recorrer varias veces el conjunto de entrenamiento.
- El orden en que se recorre el conjunto de entrenamiento debe ser aleatorio, y distinto cada vez.
- El criterio de parada:
 - Error admisible.
 - Nº máximo de iteraciones.
- η : paso o parámetro de velocidad de aprendizaje. Su valor determina la velocidad con la que la red aprende.

El conjunto de entrenamiento

ii Es esencial escoger bien el conjunto de entrenamiento !!

- Sólo **APRENDE** lo que ocurre en el conjunto de entrenamiento
- No extrapola bien



El número de nodos de la capa oculta: L

Supongamos una red como la de la figura: red

El $n^\circ L$ determina el n° de parámetros de la red:

$$n^\circ \text{ parámetros} = (N + 1) * L + M * L$$

Por tanto:

$$L \in \left[1, \frac{P}{N + 1 + M} \right]$$

Ya que la muestra de entrenamiento es de tamaño P .


El efecto de L en los resultados de la red es similar al de la **ventana** en la estimación no paramétrica:

- Valores bajos de L : la red promedia los datos del conjunto de entrenamiento (sobresuaviza)
- Valores altos de L : la red reproduce los datos del conjunto de entrenamiento (infrasuaviza)

NUESTRO PROBLEMA

Predecir el nivel de inmisión de SO_2
alrededor de la U. P. T. de Endesa en
As Pontes

RED DE VIGILANCIA DE LA CALIDAD ATMOSFÉRICA



- Recibimos datos cada 5 minutos
- La legislación controla la media horaria de la inmisión


Por tanto, nuestra variable de interés será:

X_t Media horaria arrastrada de la inmisión de SO_2 en el instante t


Tenemos una serie temporal:

$\dots, X_{t-1}, X_t, X_{t+1}, \dots, X_{t+h}, \dots$

- Habitualmente la serie $\{X_t; t = \dots -1, 0, +1 \dots\}$ se compone de valores cercanos a 0.
- En condiciones meteorológicas desfavorables, puede ocurrir un episodio de inmisión:



Red para predicción de niveles de inmisión con 1/2 hora de antelación




Nos interesa

- Predecir los episodios con antelación para que se puedan tomar medidas preventivas en la U. P. T.

Concretamente:

haremos predicciones a $\frac{1}{2}$ hora de la media horaria



Diseño del conjunto de entrenamiento

➤ ~~Serie temporal~~

➤ Matriz Histórica:

2000 registros


Divididos en estratos

Utilizamos datos de 1999


$$\left[\begin{array}{c} \underline{(X_{t-3}^1, X_t^1, X_{t+6}^1)} \\ \underline{\hspace{10em}} \\ \underline{\hspace{10em}} \\ \underline{\hspace{10em}} \\ \underline{(X_{t-3}^i, X_t^i, X_{t+6}^i)} \\ \underline{\hspace{10em}} \\ \vdots \\ \underline{\hspace{10em}} \\ \underline{(X_{t-3}^P, X_t^P, X_{t+6}^P)} \end{array} \right]$$


Resultados

20/05/2000 F4





Entradas Capa Oculta Salidas





23/MAY/00 17:0 Superficie Media Bihoraria real



Coordenadas UTM

Predicción con Datos Funcionales

Consideramos variables aleatorias con valores en:

$$H = L^2([a, b])$$

Observando un proceso estocástico en tiempo continuo: $x(t), t \leq T$

Pretendemos predecir valores futuros: $x(t), t \geq T$

Consideramos el modelo estadístico:

$$X_n = \rho(X_{n-1}) + \varepsilon_n$$

ε_n es un ruido blanco fuerte de Hilbert

$\rho: H \rightarrow H$ es el operador funcional a estimar

Técnicas de Estimación

Modelo Autorregresivo de Hilbert (ARH)

$$\hat{X}_n = \hat{\rho}(X_{n-1})$$

El estimador $\hat{\rho}$ se obtiene a partir de la expresión $D = \rho C$

con C y D matrices de covarianzas y covarianzas cruzadas.

Núcleo funcional (FK)

$$\hat{\rho}_{h_n}(x) = \frac{\sum_{i=1}^n X_{i+1} \cdot K\left(\frac{\|X_i - x\|}{h_n}\right)}{\sum_{i=1}^n K\left(\frac{\|X_i - x\|}{h_n}\right)}$$

con K núcleo gaussiano.

Aplicación

Consideramos la serie de datos como:

observaciones de un proceso estocástico en tiempo continuo
que modeliza los niveles medios horarios de SO_2

Consideramos porciones de dicho proceso estocástico que representan 1/2 hora.
Por tanto consideraremos variables aleatorias que toman valores en:

$$H = L^2([0,6])$$

de la siguiente forma: $X_n(t) = x(6n + t)$

Matriz Histórica

Necesitamos una matriz histórica adecuada a datos funcionales.
Hemos considerado una matriz formada por vectores de la forma:

$$(X_t, X_{t+1})$$

Los registros de la matriz están divididos en estratos. Cada vector se incluye en un estrato según una cierta regla de clasificación.


Por niveles:

cada estrato tiene asignado un rango de valores de inmisión, y cada vector se clasifica según el rango al que pertenezca la última observación de: X_{t+1}

Por formas:

cada estrato tiene asignada una forma funcional, y cada vector se clasifica según la forma de: X_{t+1}

17:25



Aplicación de Técnicas Estadísticas al Estudio Hidrológico de la Cuenca del Río Xallas



Wenceslao González Manteiga

María Castellano Méndez

JORNADAS LA MATEMÁTICA DEL AGUA
SANTIAGO DE COMPOSTELA , ABRIL 2002

El problema

La explotación hidroeléctrica de un río requiere un **conocimiento de los recursos**, en este caso el agua, de los que se dispondrá en un futuro, con el fin de planificar la cantidad de energía que se va a generar y el momento adecuado para hacerlo.

Nuestro objetivo es proporcionar previsiones que sirvan de ayuda en la toma de decisiones en dos situaciones diferentes caracterizadas por el horizonte temporal con respecto al que deseamos realizar las predicciones.

Abordaremos dos problemas diferentes:

- ↳ Predicción a Largo Plazo
- ↳ Predicción a Corto Plazo

Estos problemas presentarán características diferenciadas que nos llevarán a abordarlos desde diferentes perspectivas y por tanto a emplear **diferentes técnicas estadísticas** para su resolución.

El Río Xallas.

A lo largo del curso del río se encuentran situadas dos presas, la de **Fervenza**, al final de la cabecera del río, y la **Santa Eugenia**, situada justo antes de la desembocadura del río en plena *Costa da Morte*.



ATLÁNTICO

SANTA
EUGENIA

CASTRELO

PTE.
OLVEIRA

FERVENZA




Río Xallas

LAS MATEMÁTICAS DEL AGUA

Fervenza

- Entradas:
 - *Lluvia acumulada en Fervenza en los últimos 15 días.*
 - *Lluvia en Fervenza del día previo*
 - *Lluvia en Fervenza del día objetivo (previsión)*
 - *Aportaciones en Fervenza del día previo*
- Conjunto de Entrenamiento:
 - *Datos diarios del período (3454 datos)*
- Conjunto de Validación:
 - *Datos diarios del período 16 de noviembre de 2000, 31 de enero de 2001.(77 datos)*

La Red Seleccionada



$$h_j = (z_i)^k, \text{ con } 1 \leq j \leq N_I * S = N_H$$


$$j = (i-1) * S + k, \text{ con } 1 \leq i \leq N_I, \text{ con } 1 \leq k \leq S$$

Salida de la Red

Perceptrón con una Capa Funcional Polinómica

- Características de la Red Polinómica:
 - *Grado del polinomio: 2*
 - *Número de pesos: 9*
 - *Variables: $\ln(1 + vble)$*
- Características del Entrenamiento:
 - *Paso: 4×10^{-6}*
 - *Número de iteraciones: 5000*
 - *Pesos iniciales: $U(0, 0.5)$*
- Resultados del Entrenamiento:
 - *Gráficas de las predicciones frente a la real.*
- Resultados de la Validación:
 - *Error relativo absoluto medio: **0.178***
 - *Gráficas de las predicciones frente a la real*

Sección del Conjunto de Entrenamiento (16/11/1992-31/01/1993)



	16-nov-92	21-nov-92	25-nov-92	30-nov-92	4-dic-92	9-dic-92	13-dic-92	18-dic-92	22-dic-92	27-dic-92	31-dic-92	5-ene-93	9-ene-93	14-ene-93	18-ene-93	23-ene-93	27-ene-93
◆ defprev	24.739	13.600	78.202	45.433	85.488	34.552	20.628	31.852	16.322	13.368	9.827	10.179	13.895	44.241	18.787	13.225	20.563
■ defreal	23.361	14.472	67.033	34.730	71.168	38.845	24.790	30.031	19.045	15.184	11.858	9.903	12.585	35.053	20.911	14.705	15.878

Data



Conjunto de Validación (16/11/2000-31/01/2001)

