

## Ejemplo de uso de Redes Neuronales Artificiales (RNAs)

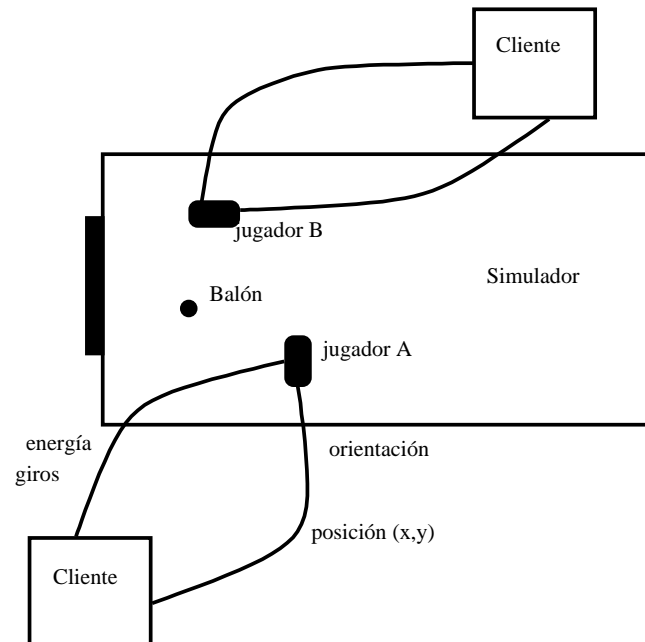
1. Enseñando a un softbot a chutar un balón
2. Integración de sensores mediante redes neuronales
3. Modelos agroclimáticos de consumo de agua

# El simulador

## ● Propiedades

1. Realista (fricción, inercia, ruido)
2. Animado
3. Basado en cliente-servidor
4. Clientes usan planificación de rutas (seguimiento balón)

## ● Arquitectura




## Enseñando a un softbot a chutar un balón

- Usaremos un simulador de fútbol, construído bajo el paradigma de los sistemas multi-agente, para enseñar a un jugador a chutar.
- Vamos a hacer uso de una red neuronal artificial
- Dos tipos de agentes,
  - un agente que pasa el balón, el **pasador**, y
  - otro que chuta a partir del pase, el **chutador**.
- La velocidad inicial de la pelota en el pase depende de la distancia desde la que el pasador empieza a moverse
- El chutador debe mantener una aceleración constante, una vez que empieza a moverse.
- La tarea  $T$ , a aprender por el chutador es **decidir cuando comenzar a moverse**.

# Escenario típico

- La tarea  $T$  depende de las coordenadas del balón y del chutador  
 $\rightarrow (x, y, \theta)$ .
- El método mediante el cual el chutador decide sus movimientos se denomina **política de chut**
- El método mediante el que elegir la línea de dirección se denomina política de dirección (*steering policy*)
- Los parámetros  $(x, y, \theta)$  varían de forma aleatoria para generar casos diferentes
  - El rango de variación para la orientación es de  $70^\circ$ .
  - $x$  e  $y$  varían de forma independiente en 40 unidades.
- El ruido es de 2 unidades para  $x$  e  $y$  y 2 grados para  $\theta$

# Escenario típico (II)

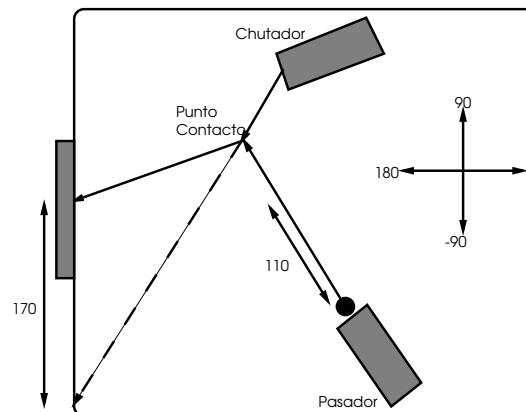


# La tarea $T$

- La dificultad en el aprendizaje de  $T$  depende de
  - Los experimentos se pueden realizar con la misma velocidad para la pelota, o con velocidad variable.
  - La bola puede moverse siempre en la misma trayectoria, o en diferentes trayectorias.
  - La portería puede estar siempre en el mismo sitio o puede moverse arriba ó abajo.
  - Tanto el entrenamiento como la evaluación se pueden realizar en el mismo sitio, o la evaluación puede moverse a otro cuadrante.
- Es posible que no sea necesario aprendizaje inductivo. Si planteamos la política de chut
  - cuando el chutador se encuentra en la orientación adecuada, debería comenzar a moverse cuando la distancia de la pelota al punto de contacto es igual o menor que 110 unidades*
- Resultado  $\longrightarrow$  una tasa de aciertos del 60,8 %.

# Experimento 1: Velocidad del balón fija

- En los pases el balón se mueve siempre en la misma trayectoria y con la misma velocidad, para todos los ejemplos de entrenamiento y evaluación.
- Condiciones base para marcar un tanto
  - Trayectoria de la pelota de 140 grados
  - velocidad de la pelota 135 units/sec,
  - intersección de línea de dirección del chutador y banda a 170 unidades de portería



# Experimento 1: diseñando la red

- La salida debe indicar si el chutador debe, o no, comenzar a acelerar en cada *time slice*
- Posible diseño


$$f(x_{pelota}, y_{pelota}, \theta_{pelota}, x_{chutador}, y_{chutador}, \theta_{chutador})$$

- Red de 6 entradas → un modelo complejo.
- Mala generalización
- Pero...



# Experimento 1: diseñando la red (II)

- Podemos predecir el punto de contacto de la pelota y el chutador.
- Con lo que podemos calcular
  - Distancia a la bola (`DistanciaBola`): distancia entre la bola y el punto de contacto,
  - Distancia del agente (`DistanciaChutador`): distancia entre el chutador y el punto de contacto
  - Desfase de orientación (`DesfaseOrientacion`): diferencia, en ángulos, entre la orientación del agente y la que considera como óptima.



# Experimento 1: conjunto de entrenamiento

- Objetivo: generar ejemplos con alta diversidad
- Usaremos una política de chut aleatoria.

*“En cada oportunidad de chut, el chutador se moverá con una probabilidad  $\frac{1}{x}$ ”*

- Conjunto de ejemplos debe ser balanceado
- Determinamos que hay 25 ciclos de simulador que van a corresponder a oportunidades en las cuales el agente puede decidir moverse antes de que la pelota esté a menos de 110 unidades del punto de contacto (i.e. el chut no sería exitoso entonces).
- Para obtener el valor de  $x$

$$P_{falla} = \left(1 - \frac{1}{x}\right) \left(1 - \frac{1}{x}\right) \overbrace{\dots}^{25} \left(1 - \frac{1}{x}\right) = \left(\frac{x-1}{x}\right)^{25} = 0,5$$

## Experimento 1: conjunto de entrenamiento (II)

- Tenemos que  $x$  es más o menos 37.
- Se generan 2990 ejemplos.
- Porcentaje de acierto del 19,7%.
- Solo 590 ejemplos fueron instancias positivas.

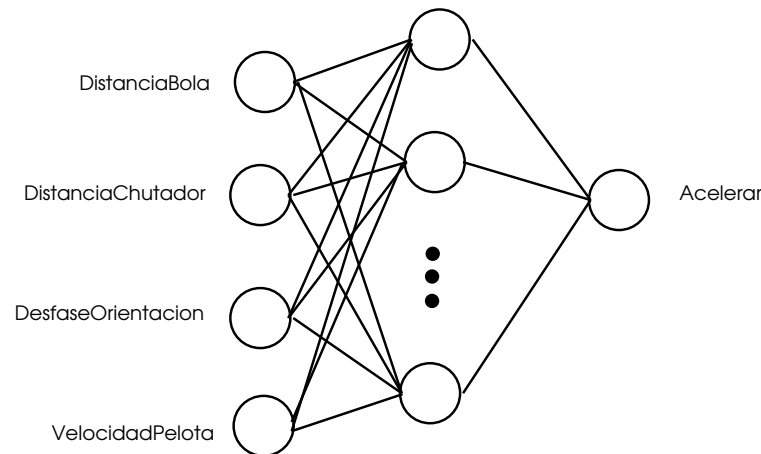
# Experimento 1: Entrenamiento y Evaluación

- Se probaron distintas configuraciones de redes neuronales sigmoidales.
- Se varió  $\eta$  y el número de nodos ocultos.
- Los ejemplos de entrenamiento se etiquetaron con un 0,9 y 0,1
- Los pesos  $w_{ij}$  con un valor aleatorio en  $[-0,5, 0,5]$ .
- La red neuronal óptima se obtuvo tras 3000 epochs, con un error RMSE de 0.0386.
- Mejora
  - Conforme la pelota se va acercando a una determinada distancia, la señal de la red se va incrementando hasta llegar a un pico. Una vez pasado ese pico, la señal comienza de nuevo a disminuir hasta llegar a un mínimo.  
Acelerar cuando  $Output \geq 0,6 \wedge Output \leq Previous - 0,1$

Posición inicial chutador	Política de chut	Éxito
Constante	Simple	100
Cambiante	Simple	60.8
Cambiante	Aleatoria	19.7
Cambiante	Regla de red de 3 nodos	96.5

## Experimento 2: Velocidad del balón variable

- Objetivo: chutador debe aprender a acelerar ante una pelota con velocidad variable.
- Variamos distancia de arranque del pasador en  $[32, 38]$  unidades
- La velocidad de la pelota variaría en  $[110, 180]$  unidades de velocidad.
- Incluimos un parámetro nuevo a la entrada de la red, `VelocidadPelota`.



## Experimento 2: Velocidad del balón variable

- La velocidad se calcula con la diferencia en posición para las 10 últimas unidades de tiempo
- Ejemplos 5737.
- El ratio de aprendizaje ha sido esta vez de 0,001 y
- el número de epochs 4000.

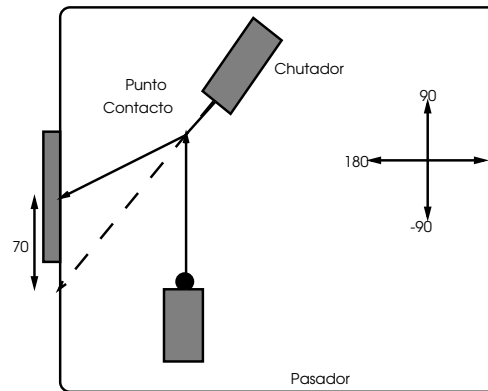
Política de chut	Aciertos
Red de 3 nodos de entrada	49.1
Aleatorio	16.8
Red de 4 nodos de entrada	91.5

## Experimento 3: Trayectoria del balón variable

### ● Hipotesis inicial

*Dado que las entradas a la red de 4 nodos, usada en el experimento 2 son relativas a PuntoContacto, la trayectoria con la que la bola se mueve hacia el chutador no va a afectar negativamente al rendimiento de la red*

### ● Test de la hipótesis → lanzar la pelota con una trayectoria de 90 grados.




### ● Resultado → efectividad del 96,3 %.

*La red de 4 entradas no solo generalizaba en diferentes áreas del campo, sino que también generalizaba a diferentes trayectorias del balón.*

## Experimento 3: Trayectoria del balón variable


- ¿Qué pasa con la variación en la dirección del chutador?
- Problema: decidir la trayectoria de chut.
- La trayectoria del balón variará en  $[82^\circ, 145^\circ]$ .
- La nueva tarea de aprendizaje será la de decidir en qué dirección debería apuntar el chutador.
- Añadiremos una nueva red neuronal a añadir a la anterior





## Experimento 3: Trayectoria del balón variable

- Objetivo → elegir los parámetros para la nueva red.
  1. `AnguloPelotaChutador`
  2. Salida será `AmplitudAngulo`
  3. Éxito en 92,8 % de las ocasiones
- Si se añade `VelocidadBola` el rendimiento es de 95,4 %.



# Fusión de sensores mediante ANNs

- Los robots necesitan recopilar información para poder realizar tareas de navegación
  - Interna mediante sensores internos (e.g. motores, inerciales, etc)
  - Externa mediante sensores de
    - ultrasonidos,
    - infrarrojos,
    - láser,
    - cámaras de visión artificial, etc
  - Cada sensor tiene un grado de incertidumbre
- El integrar información imprecisa de diferentes sensores puede redundar en la reducción de la incertidumbre global

# Integración de sensores

- Vamos a integrar sensores infrarrojos y ultrasonidos
- Tareas a desarrollar
  1. Implementación de modelos sensoriales teóricos
  2. Recopilación de datos
  3. Generación de redes neuronales
  4. Validación de los modelos obtenidos

# Sensores

## ● Sensores de ultrasonidos (sonar)

### ● Modelo Polaroid 6500

- Trabaja a frecuencias de 49.4kHz
- La amplitud máxima del rayo está entre  $15^{\circ}$  y  $20^{\circ}$
- Medidas en un rango entre 15cm y 10mt con un error de  $\pm 1\%$
- Tipos de error
  - ◇ Pérdida de señal de eco
  - ◇ Incertidumbre debida a la apertura angular
  - ◇ Rebotes dobles

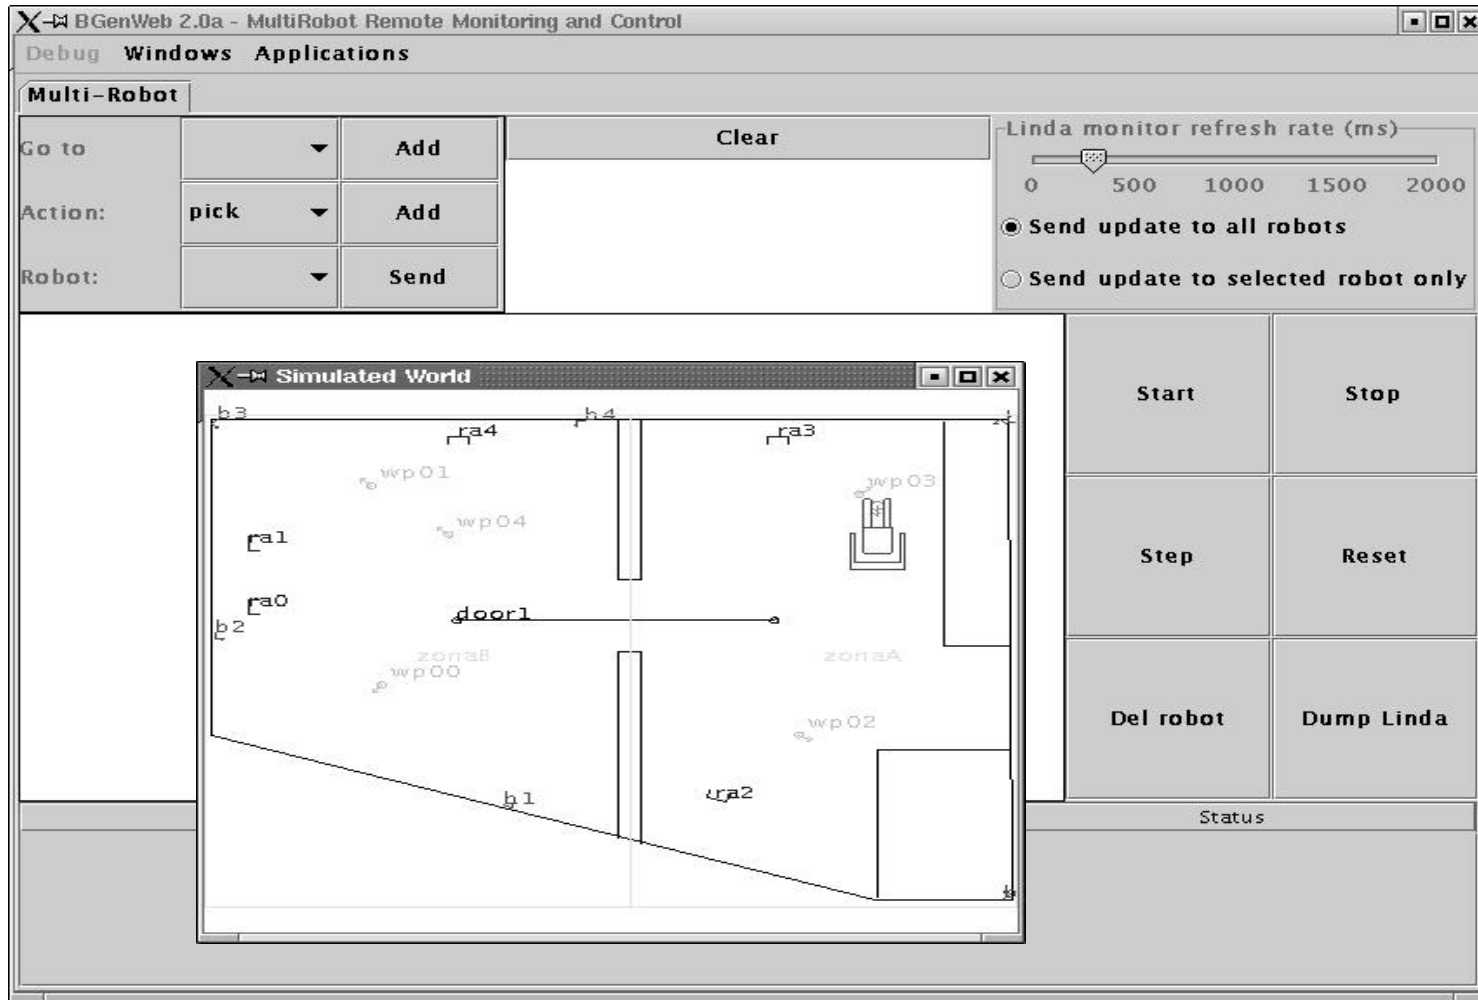
## ● Sensores de infrarrojos

### ● Modelo Sharp GP2D02

- Usa un emisor LED y un detector de luz PSD
- Medidas aceptables entre 10 y 120cm
- Tipos de error
  - ◇ Reflectividad variable según color del objeto
  - ◇ Iluminación global
  - ◇ Error de cuantificación


## ● Se usa un modelo teórico para cada uno de los sensores

# Entorno de simulación



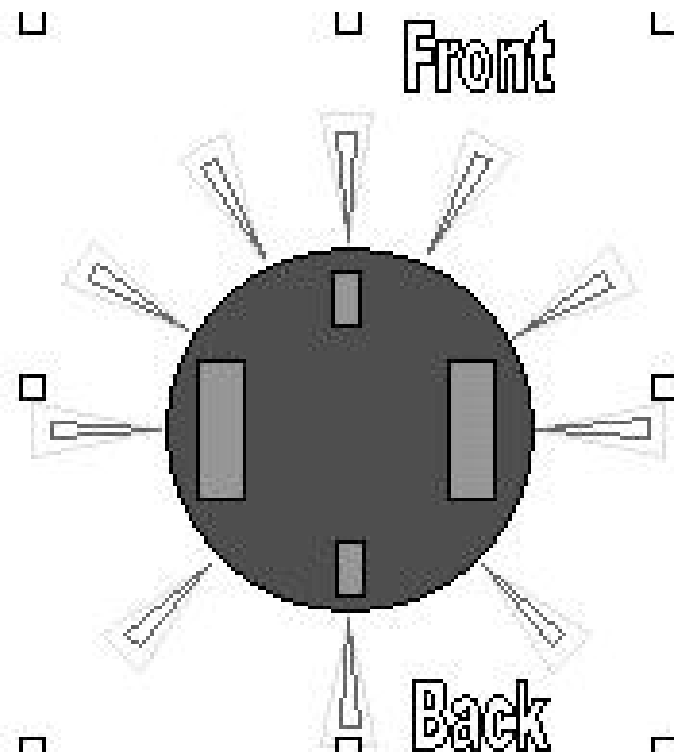
# Escenarios para simulación

- Dos escenarios diferentes
  - Sótano de la facultad
  - Planta del concurso de robots del Trinity College



# Robot a simular

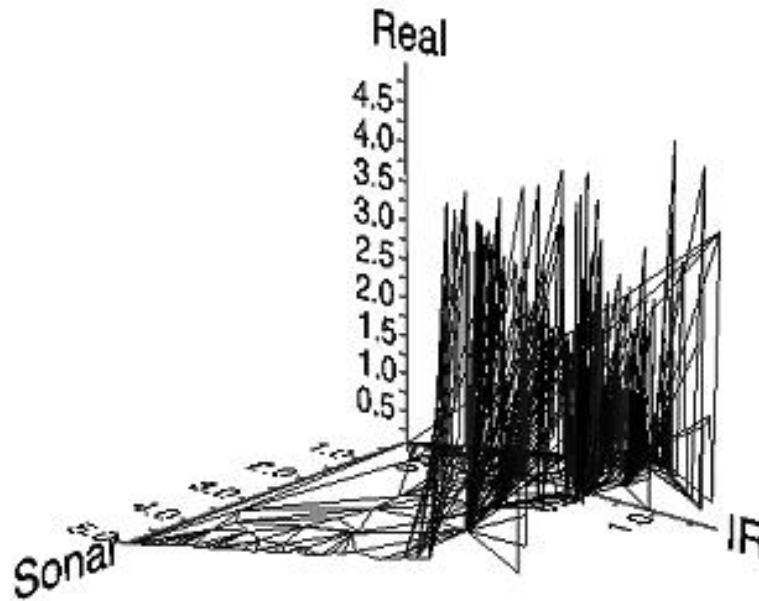
- Robot holónomico
- 2 ruedas de dirección y dos ruedas libres
- 10 pares de sensores de infrarrojos y ultrasonidos



# Datos para el análisis

- Las triplas están definidas como

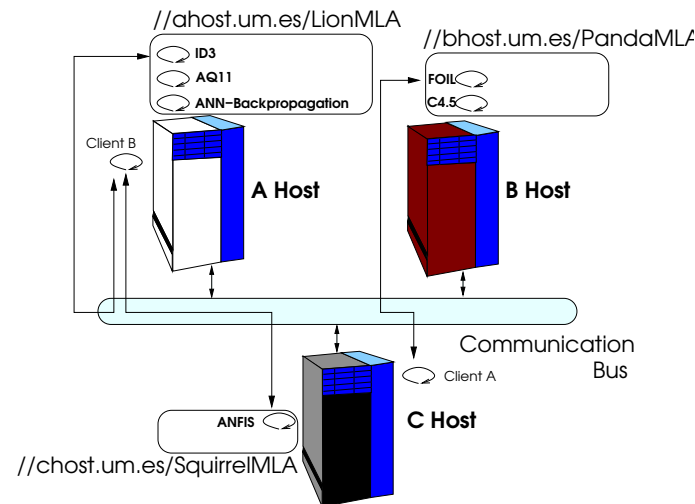
$\langle \textit{sonar}, \textit{ultrasonido}, \textit{real} \rangle$






# Ejecución de algoritmos de aprendizaje

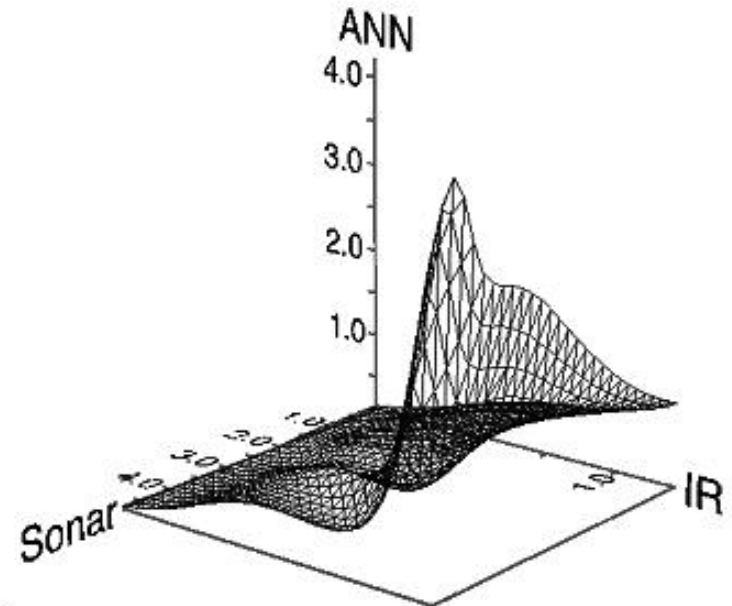
- Cuatro máquinas diferentes
- Parámetros de configuración
  - Número de nodos ocultos (desde 5 a 80, con saltos de 5)
  - ratio de aprendizaje  $\mu$  (desde 0.01 a 0.16, con saltos de 0.05)
  - momentum
  - epochs
  - Total de 65 experimentos



# Resultados




Errores




Superficie producida por la red

# Validación

- La fusión de sensores de la red la comparamos con el algoritmo de Flynn
  1. Si la lectura del sonar es mayor que el rango máximo del sensor de infrarrojos, ignorar el sensor de infrarrojos
  2. Si la lectura del sonar produce su valor máximo, la distancia real es mayor
  3. Cuando el sensor infrarrojo presenta un cambio de no detección a detección y la lectura del sónar es menor que diez pies entonces se ha detectado un objeto



Flynn



RNA

# Predicción de necesidades hídricas en un cultivo

- poder predecir las necesidades de agua de riego resulta un factor clave para una gestión adecuada de ese valioso recurso (se agrava en Murcia)
- el término  $ET_0$ : la cantidad de agua evaporada desde el suelo y transpirada a través desde la superficie folial de la planta
- esta cantidad es la que el cultivo necesita posteriormente para obtener una cosecha óptima
- Para ajustarla a un cultivo determinado

$$ET_{cultivo} = K_c \times ET_0$$

- Finalmente, la cantidad de agua que se necesita es

$$Ar = ET_{cultivo} - P_{efectiva}$$

# Modelo de Cubeta Clase A para $ET_0$

- Basado en la observación de cambios de nivel de agua en una cubeta calibrada
- Su formulación es muy simple

$$ET_0 = K_p \times E_0$$

●  $K_p =$

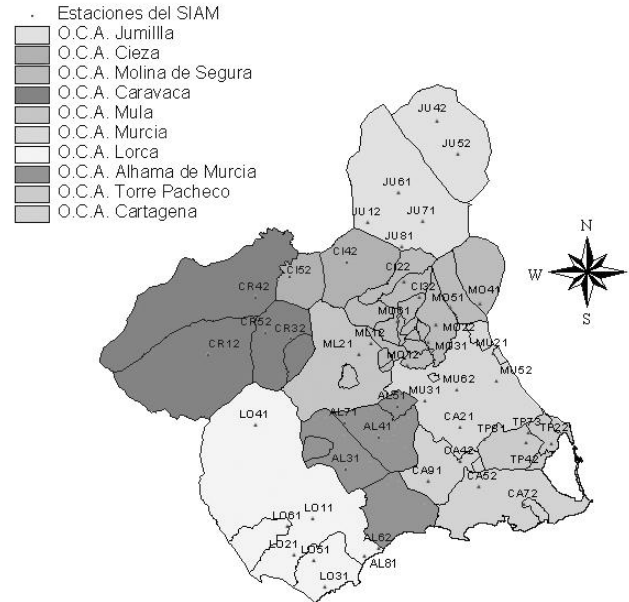
$$a_0 + a_1 U + a_2 \overline{H}_r + a_3 d + a_4 \overline{H}_r^2 + a_5 d^2 + a_6 U \overline{H}_r^2 + a_7 d \overline{H}_r^2$$

● donde

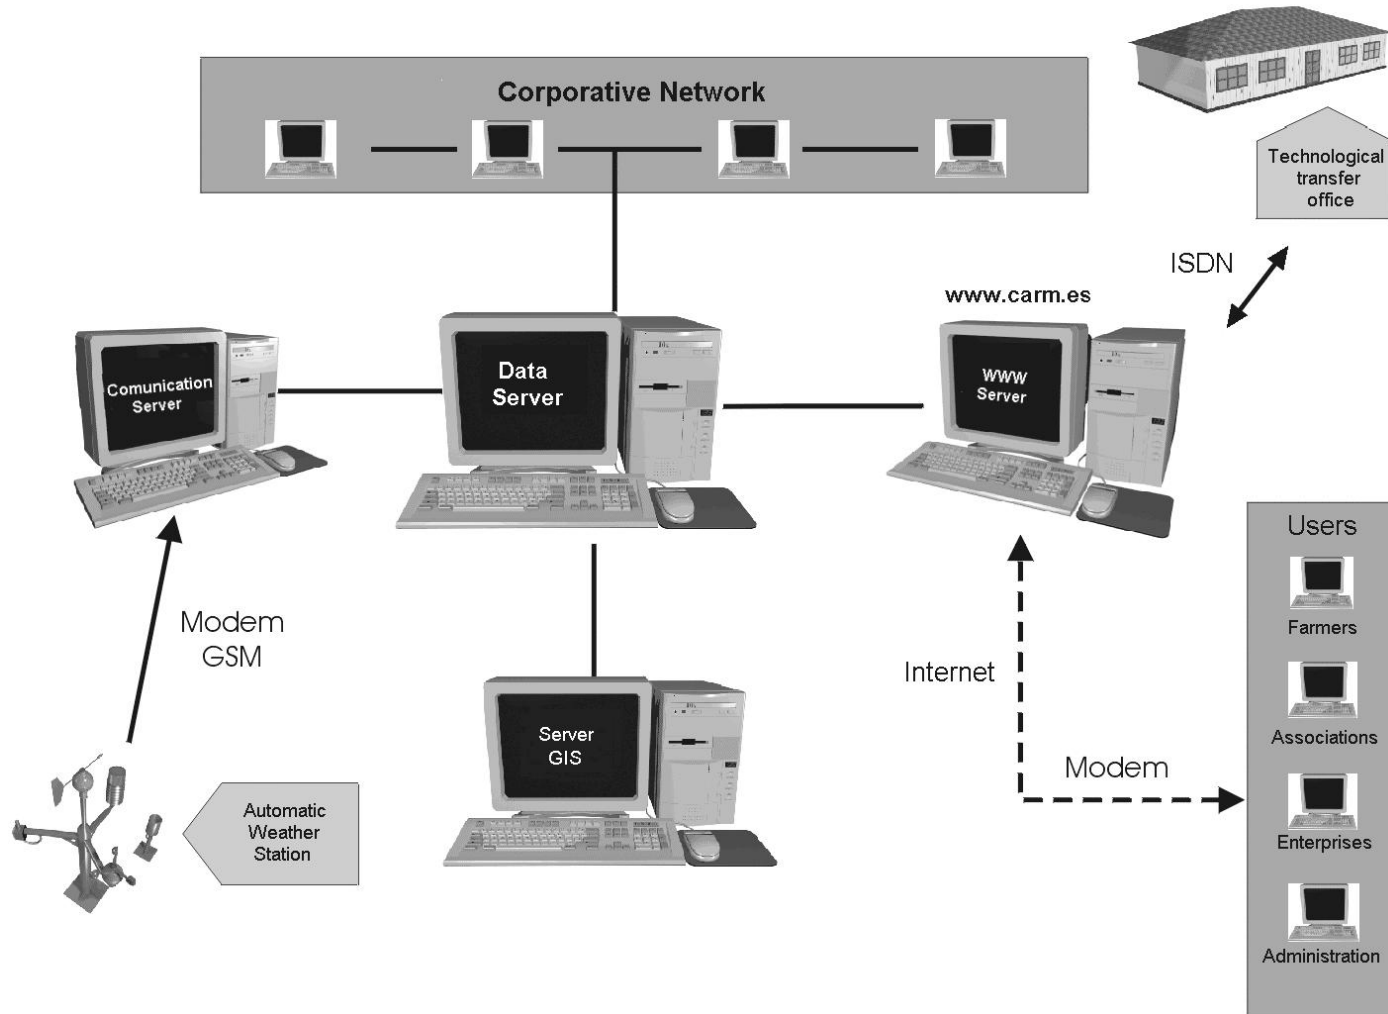
- $a_i$ ,  $1 \leq i \leq 7$  y  $d$  son coeficientes obtenidos en una situación ideal reproducida en laboratorio
- $U$  es la velocidad media del viento
- $\overline{H}_r$  es la humedad relativa media
- y  $E_0$  es el agua evaporada en un día, en una cubeta calibrada

# Modelo de Cubeta Clase A para $ET_0$ (II)

- muy impreciso, por su dependiencia de varios elementos físicos
- usado intensivamente en Murcia en un sistema de información compuesto por 64 estaciones agroclimáticas



# Recogida de datos



# Recogida de datos (II)

- 64 estaciones tomando medidas horarias
- BD relacional con tablas Hora, DIA, SEMANA, MES y AÑO.
- el valor de  $ET_0$  se puede estimar haciendo uso de  $\overline{H}_r$ ,  $U$  y  $E_0$ 
  - Los tres los mide cada estación
  - Un experto corrige los valores sobre la tabla SEMANA que son dos de los parámetros que mide cada estación



# Características de los datos

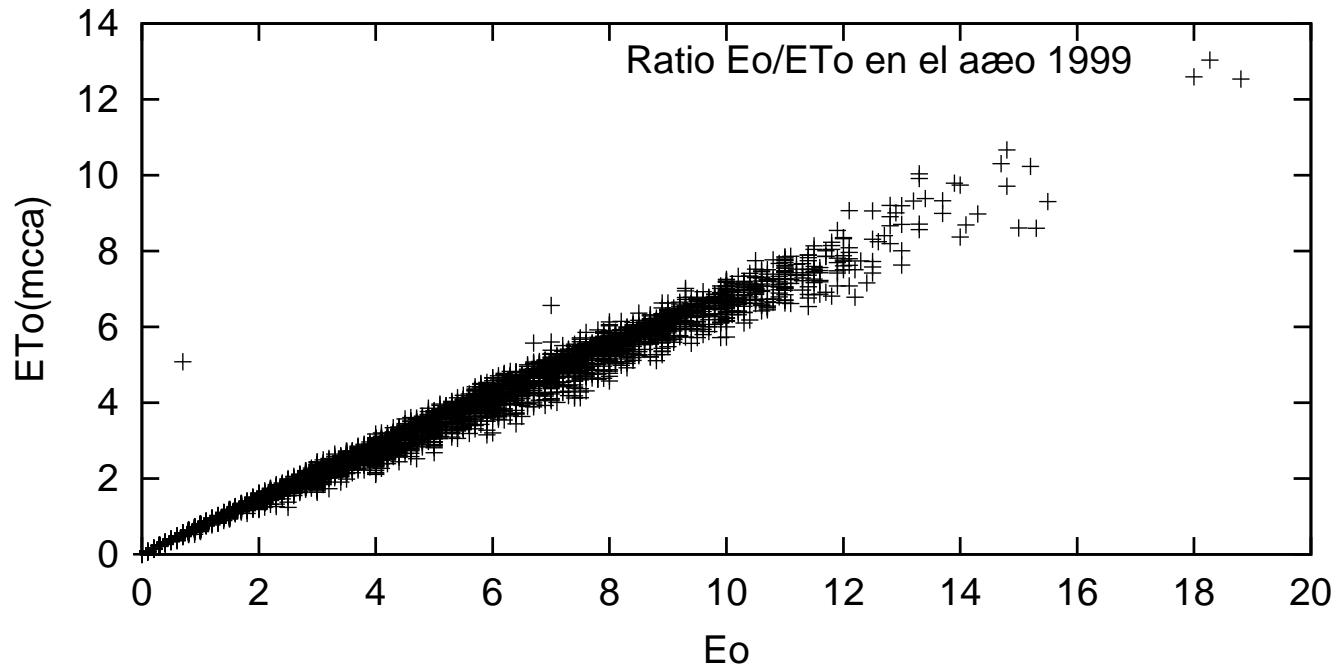
- Existen estaciones funcionando desde 1994
- Si definimos el MCCA en forma analítica, como una función obtenemos la siguiente:

$$f_{mcca} : \overline{H}_r \times U \times E_0 \rightarrow ET_0$$

- El problema se reduce a obtener  $\hat{f}_{mcca}$  que aproxime
  - comportamiento correcto del MCCA en algunos casos
  - conocimiento implícito del experto al realizar las correcciones en el mismo

# Estudio preliminar de datos

- Si nos tomamos un tiempo para el estudio se puede descubrir rápidamente que  $E_0$  y  $ET_0$  está fuertemente correlados positivamente





- Es posible que un modelo lineal se comportara lo suficientemente aproximado como para tomarlo por bueno

# Valores nulos

- la tabla `DIA` presenta una proporción de valores nulos considerable
  - debida principalmente a períodos en los cuales alguna de las estaciones agroclimáticas se encontraba sin funcionar (o funcionaba incorrectamente)
  - un total de 53533 tuplas, de las cuales 30958 eran válidas y el resto presentaban nulos
- Los atributos  $U$  y  $\overline{H}_r$  presentan menos del 8% de valores nulos
- $E_0$  tiene nulos en el 35% de las correspondiente tuplas
- Posible solución al problema: obtener la media de todos los valores válidos, y sustituir todos los nulos por ese valor
  - el valor de *skewness* del atributo es 26.001 que sugiere que la distribución de probabilidad se aleja bastante de una normal

# Valores nulos (II)

- Podemos aprovechar las características propias de los datos, derivadas de las magnitudes a las que representan
- Es razonable pensar que  $E_0$  en una estación está fuertemente relacionado con otros valores, tomados de estaciones diferentes, en la misma fecha de años anteriores o posteriores




# Valores nulos (III)

- Con el método anterior se restauraron 608 tuplas
- insuficiente al quedar todavía 12923 tuplas sin recuperar
- Segunda posibilidad
  - tenemos aun 38 estaciones con una cantidad de nulos mayor que el 15 % de sus tuplas.
  - Método basado en estaciones de referencia: estación de referencia será aquella que tenga una cantidad de nulos despreciable
  - Idea: usar valores de estaciones de referencia, para recuperar los nulos de otras
    - Si la estación  $E_a$  es la estación de referencia de la estación  $E_b$ , las dos estaciones son muy similares en sus valores para  $U$ ,  $\overline{H}_r$  y  $E_0$
    - $E_a$  se puede usar para aportar valores a  $E_b$
    - Medida de similaridad

$$d(E_a, E_b) = \sum_{i=1}^n \sqrt{(\hat{H}_{r, E_a}^i - \hat{H}_{r, E_b}^i)^2 + (U_{E_a}^i - U_{E_b}^i)^2}$$

# Estaciones de referencia



# Experimentos de aprendizaje

- Todos los modelos obtenidos se evaluaron usando holdout con el mismo cjto. de evaluación para todos: tuplas válidas del año 1998 de la tabla DIA
- Modelo de regresión lineal es

$$\hat{f}_{cab} = 0,66354E_0 + 0,132150$$

con error de generalización de 0,25286

# Experimentos de aprendizaje

## ● MLPs

Nn	TEVV	EEVV	TERV	EERV
1	1.19238	1.38206	0.411108	0.46175
6	0.31979	0.38314	0.32427	0.37386
11	0.16291	0.24857	0.35851	0.38667
16	0.28416	0.51657	0.23810	0.23629
21	0.31988	0.39322	0.22488	0.17494
26	0.15170	0.23556	0.24529	0.22742
31	0.15402	0.23074	0.23800	0.24596
36	0.13432	0.20072	0.23934	0.22918
41	0.13423	0.20619	0.23103	0.20122
46	0.15531	0.25566	0.24398	0.22562



# Experimentos de aprendizaje (II)

## ● MLPs

Nn	TEVV	EEVV	TERV	EERV
51	0.13537	0.23017	<b>0.22116+</b>	0.18055
56	0.14567	0.23073	0.22889	0.18499
61	0.14720	0.23732	0.23481	0.19147
66	0.14330	0.22237	0.22160	<b>0.16904*</b>
71	0.14090	0.20245	0.23480	0.21365
76	0.15718	0.22870	0.23517	0.23576
81	0.13654	<b>0.16419*</b>	0.22765	0.19015
86	<b>0.12754+</b>	0.18809	0.22725	0.17385
91	0.14530	0.28109	0.22717	0.18448
96	0.14291	0.21121	0.22885	0.18115

# Conclusiones

- se obtienen errores similares de evaluación con los dos conjuntos de entrenamiento: 0.16419 y 0.16904
- existe una diferencia apreciable entre los errores mínimos de aprendizaje, 0.12754 y 0.22116
- el conjunto de tuplas reconstruidas es un 60 % más grande que el conjunto formado solamente con tuplas válidas
- la efectividad del método de reconstrucción queda demostrada con las medias aritméticas en los errores para ambos grupos de experimentos: 0.31244 y 0.23441