

Desarrollo de un prototipo de sistema portátil para la detección en tiempo-real de la necesidad de riego en cultivos de producción intensiva

J. Toloza^{1,3}, L. Leiva^{1,4}, A. Riba², F. Carmona², N. Acosta¹

¹Universidad Nacional del Centro de la Provincia de Buenos Aires (Tandil)

²Universidad Nacional de Chilecito (Chilecito)

³Becario ANPCyT

⁴Becario CONICET

{jmtoloza, lleiva, nacosta}@exa.unicen.edu.ar, {fbcarmona, ariba}@undec.edu.ar

Abstract. Para la producción agrícola intensiva de campos es de vital importancia reducir el consumo de agua, tanto por la ecología como por el impacto que tiene el costo de electricidad destinada a riego. En este artículo se diseña un dispositivo portátil que permite determinar el momento óptimo de riego de los cultivos. Para ello se utiliza un sensor de reflectancia conectado a un microcontrolador donde corre una red neuronal entrenada. Esta versión del prototipo se ha entrenado con datos de pasto.

Keywords: sensores remotos, agricultura de precisión, sensor para riego, riego óptimo.

1 Introducción

La creciente necesidad de lograr un equilibrio hidrológico que asegure el abastecimiento suficiente de agua a la población se logrará armonizando la disponibilidad natural con las extracciones del recurso mediante el uso eficiente del agua. Es un problema actual que cada día ocupa más la atención de científicos, técnicos, políticos y en general, de muchos de los habitantes del planeta.

Es por esto que, la gestión del recurso deberá tender a evitar situaciones conflictivas debidas a escasez, sobreexplotación y contaminación, mediante medidas preventivas que procuren un uso racional y de conservación.

El sector agrícola es el mayor consumidor de agua con el 65%, no sólo porque la superficie irrigada en el mundo ha tenido que quintuplicarse sino porque no se cuenta con un sistema de riego eficiente.

Se debe tener en cuenta que los campos de producción intensiva hay dos costos que son significativamente exagerados comparados al resto: los fertilizantes y la electricidad destinada al riego. Así que también la optimización del uso del agua dedicada al riego tiene un impacto directo en la reducción de costos.

Ante estas circunstancias muchas regiones del mundo han alcanzado el límite de aprovechamiento del agua, lo que los ha llevado a sobreexplotar los recursos hidráulicos superficiales y subterráneos, creando un fuerte impacto en el ambiente.

Las pérdidas de agua dulce en la red de distribución son escandalosas. 25-50 % en Urbanas y 40-60% en Agrícolas.

El desafío es optimizar la productividad de los recursos hídricos, especialmente en la agricultura, sector al que se destina la mayor parte de esos recursos en todo el mundo y en el que, sin embargo, muchas de las prácticas de rutina que se emplean para el uso del agua suelen ser ineficientes [1].

1.1 Necesidad de riego en plantaciones

Se establece una línea debajo de la cual la planta necesita agua. Toda planta que crece bajo riego tiene un punto óptimo de crecimiento que varía entre un máximo y un mínimo. El máximo es la capacidad del campo, que es la máxima cantidad de agua que puede tener el suelo y el mínimo es el 30 % por debajo de la capacidad del campo. Una planta que esta entre la capacidad del campo y el 30 % de la capacidad del mismo no consume energía para tomar el agua del suelo porque hay mucha agua disponible para la planta y la misma crece libremente sin problema. Cuando se riega, en el suelo hay partes iguales de aire y agua. A medida que la planta consume el agua va quedando más aire en el suelo. Con poca agua la planta tiene que gastar mas energía para sacarla ya que a partir de un determinado punto poder tomar esa agua le cuesta mucho esfuerzo. Todo eso se transforma en consumo de energía.

Cuando se tiene por arriba del 70% de agua no hay esfuerzo por parte de la planta, pero cuando esta por debajo, la planta empieza a gastar energía para sacar agua del suelo. De esta manera le lleva mucho esfuerzo tomar el agua y empieza a tener síntomas de falta de agua. Ese punto es un punto de marchites temporaria porque se riega la planta y se recupera, ese es un punto critico.

El riego por goteo es como regar una planta en una maceta porque se conoce el espacio que hay y está restringido. En el suelo se tiene un bulbo con cierta capacidad y se llena para que la planta vaya consumiendo agua de ahí. Por lo tanto, se puede saber cuanta agua tiene el bulbo y se puede saber más o menos que consumo tiene la planta. Con esto lo que se busca es que no estén verdes porque de esa manera podrían morirse

La cantidad de agua que necesita un cultivo es igual a la constante evapotranspiración de referencia multiplicada por dos coeficientes, uno es el coeficiente del cultivo (K_c) y el otro es el coeficiente relacionado al tamaño de la planta (K_r). El resultado de esta multiplicación permite conocer cuanta agua necesita la planta.

1.2 Detección de necesidad de agua en cultivos

Todos los organismos fotosintéticos contienen uno o más pigmentos capaces de absorber la radiación visible que iniciaría las reacciones fotoquímicas y fotosintéticas. Dos bandas del espectro, la azul (430 nm) y la roja (58-68nm) muestran

la cantidad de energía absorbida por las plantas; en contraste, la banda del infrarrojo cercano (725-1100nm), región invisible para el ojo humano, actúa justo de forma inversa. La mayor absorción del rojo y azul, junto con la fuerte reflexión del infrarrojo cercano es la diferencia espectral de la respuesta de toda la vegetación, y ha sido usado durante mucho tiempo como forma de diferenciación de las superficies con y sin vegetación [2].

En efecto, la radiación reflejada por una hoja en la región visible depende fundamentalmente de la radiación absorbida por los pigmentos de la hoja, mientras que en el infrarrojo cercano, en la región de 0.7 a 1.3 μm , depende de la estructura interna de la hoja. El estrés vegetal suele manifestarse cuando por efecto de factores como sequía, enfermedades, infección por plagas, etc., la hoja ve reducido su contenido de agua. Esto produce el colapso de las células del mesodermo inferior, lo cual reduce la reflectancia en el IR cercano, constituyendo un síntoma previsual de estrés ya que suele manifestarse días e incluso semanas antes de que comiencen a apreciarse cambios visualmente.

2 Experimentación y captura de muestras

2.1 Origen y disposición de muestras

Se toman muestras de pasto con tierra en dos bandejas plásticas de 50cm x 40cm y 5cm de profundidad. Se colocan en un ambiente cerrado y controlado en las inmediaciones de una ventana que da al exterior para que sean alcanzadas por el sol y aire proveniente del exterior.

2.2 Proceso de regado

Se establecen forma y tiempo de riego y el riego se hace con un pulverizador. Se decide aplicar una dosis de agua a una de las bandejas y la mitad a la otra para ver cuál es su efecto y como varía su estado. Se comienza regando las bandejas una vez por día con una cierta dosis. Luego se modifica el proceso llegando a regarse dos veces por día y se aumenta la dosis al doble dado que se detecta de manera visual la falta de agua.

2.3 Adquisición de datos

El proceso de toma de datos se realiza con un sensor de luz única que puede medir la reflectancia del dosel vegetal tanto de día como de noche de la empresa Holland Scientific, Inc. Modelo Crop Circle ACS-210 en ámbar [3], [4]. Se prototipa una placa de desarrollo con un microcontrolador marca Microchip modelo PIC18F4550 [5] para la recolección de datos con interfase serie RS232. La captura se realiza por puerto serie a una velocidad de 38400 baudios y se almacenan en una tarjeta flash. El

sensor trabaja a una frecuencia de 10 hz pudiendo configurarse como máximo a 20 Hz. Las tomas se organizan en un principio de una por día, luego se aumenta a dos y finalmente a tres.

La muestra en cada toma de datos en una tupla que considera las siguientes 10 variables características: Valor NDVI, Reflectancia visible, Reflectancia infrarroja, Temperatura ambiente, Temperatura exterior, Humedad, Estado del cielo (nublado, soleado, etc.), Dosis de agua regada, Diferencial de tiempo entre riego y toma de datos, Iluminación, se consideran los siguientes estados (con luz artificial y natural, con luz artificial y sin luz natural, sin luz artificial y con luz natural y, sin luz ni artificial ni natural).

También se realiza una adquisición de muestras con pasto de la mejor calidad, capturando diferentes porcentajes de área con materia orgánica y no orgánica. Se toman 180 muestras en el exterior con 100%, 75%, 50%, 25% y 0% de área orgánica.

2.4 Planificación

En un principio se realiza una toma de datos luego de una hora de haber sido regada la muestra. Con el tiempo se cambia la planificación establecida y se realizan dos tomas de datos, una antes de ser regada y otra luego de dos horas de regada.

Por último se realizan tres tomas de datos y se aumenta el regado a dos veces por día. De esta manera, se hace una toma de datos antes de regar, se riega, luego otra toma de datos a dos horas o menos de regarse, se riega nuevamente y por último la tercera toma de datos luego de dos horas o menos del segundo riego.

2.5 Resultados

Se observa el comportamiento de la vegetación en ambas bandejas y la bandeja con menor dosis de agua muestra una vegetación más seca que la otra. A medida que pasa el tiempo se diferencian considerablemente entre sí; y si se observan los valores de algunas de las variables acusan el mismo comportamiento pero sólo en algunos casos, en otros no es tan claro. Por esta razón, se debe analizar de manera global e incluir todas las variables en la clasificación para poder determinar con mayor grado de exactitud el estado de la vegetación.

Se establecen 10 variables características como entradas al sistema clasificador. Cada muestra comprende 8 casos que son: en primer lugar la bandeja con una cierta dosificación y las 4 combinaciones de luces, los otros 4 casos son igual pero con la otra bandeja con la mitad de dosificación. En resumen, se obtienen 464 archivos con el total de 27840 muestras. A estos registros se agregan otros 180 de muestras tomadas en el exterior. De las muestras tomadas se obtienen máximos, mínimos y promedios para todas las variables características y en la etapa de entrenamiento de la red neuronal se usan sólo los promedios.

3 Placa de desarrollo

La placa permite trabajar con diferentes fuentes de entrada analógica o digital, para almacenar, procesar y comunicar hacia el exterior los resultados obtenidos. Posee interfaz serie (RS232) y USB. Donde la interfaz serie se utiliza para comunicarse con el sensor ACS210 y la USB para pasar datos a la PC.

4 Sensor utilizado

Para estudiar el porcentaje e intensidad de la cobertura vegetal de una zona mediante imágenes satelitales, se acostumbra a utilizar lo que se conoce como Índices de Vegetación. El principio en que se basan éstos índices es el fuerte contraste existente entre la reflectancia de las plantas en el rojo y el infrarrojo cercano. En las plantas con actividad fotosintética, las moléculas de clorofila, responsables de esta función, absorben la luz roja. Por otro lado, las células de las hojas, en un estado de turgencia normal, reflejan la mayor parte de la radiación infrarroja que reciben.

La vegetación verde y vigorosa refleja mucho menos en la banda visible roja (banda 1), región de absorción de la clorofila, que en la banda cercana infrarroja (banda 2), región de alta reflectancia del componente celulósico. Estas propiedades llevaron a definir varios índices de vegetación basados en operaciones algebraicas entre las bandas 1 y 2. Uno de los algoritmos más conocidos es el del llamado Índice Diferencial de Vegetación Normalizado (NDVI, en inglés). Su rango de valores es de -1 a 1. De esta manera, las zonas de mayor concentración de biomasa fotosintéticamente activa presentan valores próximos a 1 y las de menor biomasa, valores más pequeños. El NDVI se calcula de la siguiente manera:

$$\text{NDVI} = (\text{banda 2} - \text{banda 1}) / (\text{banda 2} + \text{banda 1}). \quad (1)$$

El intervalo de valores obtenido del NDVI, varía entre -1 y +1. Sólo los valores positivos corresponden a zonas de vegetación. Los valores negativos, generados por una mayor reflectancia en el visible que en el infrarrojo, pertenecen a zonas de suelo desnudo y rocas [2].

Valores muy bajos de NDVI, del orden de 0.1, corresponden a áreas rocosas, arenosas o nevadas. Valores de 0.2 a 0.3 pueden corresponder a áreas pobres con arbustos o pasturas naturales. A partir de estos valores tendremos los niveles correspondientes a praderas, cultivos, forestaciones etc. dependiendo el valor alcanzado, que puede llegar hasta 0.6 y 0.8, del estado de desarrollo y sanidad de tales áreas.

El sensor de ACS-210 proporciona datos de índice vegetativo clásico, así como información básica de reflectancia de follaje de la planta. Es un dispositivo portátil que permite leer el estado de las plantas con independencia de la luz ambiente. El sensor transmite a través de RS-232, trabajando en los siguientes espectros:

- Bandas de emisión: ACS-210(Yellow/NIR) 590nm y 880nm; ACS-210(Red/NIR) 650nm y 880nm

- Foto detección: Matriz de fotodiodo de silicio con rango espectral de 320nm a 1100nm
- Visible: Detector de 1: 400nm a 680nm; Detector de 2: 800nm a 1100nm

5 Clasificación de muestras

El conjunto de datos adquirido por los sensores, es procesado por un clasificador que se encarga de determinar la categoría a la que pertenece cada una de las muestras de entrada. Un clasificador opera en tres fases: una fase de entrenamiento, una de evaluación y una de ejecución. Durante la etapa de entrenamiento se le brinda al clasificador el conocimiento acerca del dominio de aplicación. El conocimiento es denominado conjunto de entrenamiento y está comprendido por la información representativa de un conjunto de muestras que caracterizan a las principales clases de objetos. Independientemente del paradigma adoptado, el clasificador debe ser evaluado en cuanto a la confiabilidad que presentan sus salidas. Este es un problema que surge en la práctica que puede ser resuelto mediante la asociación de un parámetro de confianza a cada decisión tomada por el clasificador [6]. Para esto, se utiliza una porción del conjunto de muestras con sus respectivas categorías de manera de determinar la eficiencia del clasificador.

La técnica de clasificación utilizada es a través de una red neuronal RBF [7], [8], [9]. Estas redes se ajustan de manera adecuada al problema, siendo utilizada comúnmente en aplicaciones de clasificación, sin la necesidad de realizar modelos estadísticos complejos. Asimismo, poseen una estructura simple de implementación y el tiempo de entrenamiento se ve reducido en comparación con otras técnicas neuronales.

El vector de entrada de la red, comúnmente denominado vector característico, está compuesto por los datos adquiridos de los sensores. Estos datos son normalizados de manera de poseer valores comparables a la hora de realizar la clasificación. Asimismo, se establece un ancho de dato de 1 byte para cada una de las componentes del vector, de manera de simplificar los cálculos en la implementación final del dispositivo. El vector característico se compone de los siguientes valores adquiridos:

| | | | | | | | |
|------|----|-----|--------|---------------------|---------------------|---------|-------|
| NDVI | IR | Vis | Tiempo | Temperatura Externa | Temperatura Interna | Humedad | Dosis |
|------|----|-----|--------|---------------------|---------------------|---------|-------|

El conjunto de datos de adquiridos consiste en un número total de 464 muestras recolectadas a partir de los sensores de entrada. Cada una de estas muestras normalizadas, se encuentra asociada a una categoría definida. Las categorías se definen a partir de un parámetro que es la distancia de tiempo que paso entre el riego y la toma de datos. Se establecen cuatro categorías y el criterio adoptado es el siguiente:

- Categoría 1 (Bien): si el tiempo entre el último riego y la toma de datos está entre 0 y 12 horas.
- Categoría 2 (Media): de 12 a 24 horas desde el último riego a la toma de datos

- Categoría 3 (Necesitada): si pasaron de 24 a 48 horas desde el último riego
- Categoría 4 (ReNecesitada): mas de 48 horas desde el último riego

Del número total de muestras se establece un subconjunto de entrenamiento compuesto por un total de 200 vectores característicos escogidos de manera aleatoria, los cuales son utilizados para el entrenamiento de la red. El subconjunto de muestras restantes es utilizado como conjunto de testeo, para realizar la evaluación del clasificador.

Como resultado del proceso de entrenamiento se obtiene una red neuronal compuesta por un número total de 21 neuronas con un campo de influencia inicial para cada una de las neuronas de 500, con los siguientes números de neuronas por categoría:

Tabla 1. Distribución de neuronas en las diferentes categorías luego del entrenamiento.

| Categoría | Número de neuronas |
|--------------|--------------------|
| Bien | 5 |
| Media | 10 |
| Necesitada | 3 |
| ReNecesitada | 3 |

Esta red sometida a la evaluación, con el subconjunto restante, da como resultado una identificación correcta de 256 muestras (96.6%), mientras que las 9 restantes son clasificadas como inciertas (3.4%), de las cuales si bien perteneces a más de una categoría, una de estas es la correcta. El número total de aciertos por categoría es el siguiente.

Tabla 2. Aciertos por categorías obtenido luego de la etapa de evaluación.

| Categoría | Número de aciertos |
|--------------|--------------------|
| Bien | 187 |
| Media | 112 |
| Necesitada | 4 |
| ReNecesitada | 3 |

Analizando los resultados de la evaluación realizada, se puede afirmar que el clasificador actúa de manera adecuada, ya todas las muestras de entrada son identificadas por al menos una neurona. Asimismo, no existen errores en cuanto a la categoría a la cual se las asocia, convirtiéndose de esta manera en un clasificador óptimo para atacar el problema. Si bien existe un conjunto de muestras, las cuales son consideradas como inciertas, este conjunto puede aparecer debido a que los valores se encuentran muy próximos a los límites de las regiones características.

6 Arquitectura hardware

La implementación de técnicas neuronales en hardware dedicado posee un número importante de ventajas, dentro de las cuales se destaca la velocidad de proceso. Los procesadores convencionales están imposibilitados de proveer respuesta y entrenamiento en tiempo real para redes con grandes números de neuronas y sinapsis, por lo que el procesamiento paralelo con múltiples elementos de procesos simples logra un gran incremento de velocidad. Si bien, en este caso, la velocidad no es un factor fundamental, y es posible realizar una implementación mediante el uso de una PC, se debe recordar que el sistema está orientado al diseño de un dispositivo portátil, capaz de realizar una clasificación efectiva de las muestras en tiempo real.

Existen varias implementaciones hardware de redes neuronales como son los dispositivos IBM ZISC78, Hitachi Digital Chip Philips L-Neuro 1.0, Nestor Ni 100 [10], [11], [12], entre otros. Si bien, el uso de estos dispositivos simplifica el diseño, se propone la realización de una arquitectura específica de manera de abaratar costos, a través de la utilización de una FPGA. Estos dispositivos poseen la capacidad de ser reprogramados, por lo que el sistema puede ser adaptado de manera sencilla a futuras aplicaciones en otras áreas, incorporar nuevos sensores o ajustar el sistema para aplicarlo en otro tipo de cultivos.

La arquitectura del sistema se presenta en la Fig.1 donde los datos adquiridos por los sensores son capturados y transformados, en el caso que lo requiera en una versión digital. El conjunto de muestras capturadas forman la entrada a la FPGA, que se encarga del procesamiento para brindar como salida la categoría a la que pertenece la muestra.

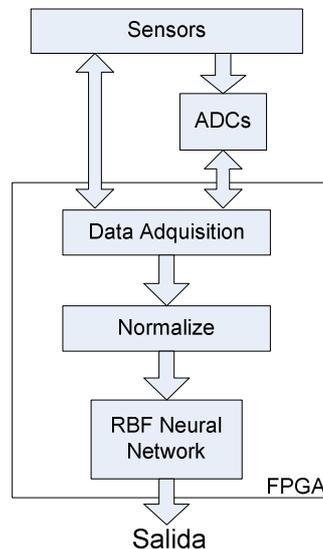


Fig. 1. Arquitectura hardware.

El conjunto de datos proveniente de los sensores pueden ser digitales o analógicos. Los datos analógicos forman la entrada de convertidores analógicos digitales (ADCs)

que transforman las señales a un estado digital, de manera que puedan ser procesados por la arquitectura.

La arquitectura emplazada dentro de la FPGA, está compuesta por un módulo de adquisición de datos (Data Acquisition) que se comunica con los sensores de manera de capturar los datos en su forma digital, así como también con los conversores ADCs. Estos datos son la entrada de un módulo encargado de la normalización de los mismos (Normalize), para formar el vector característico que es la entrada de la red neuronal (RBF Neural Network). Como resultado se obtiene la clase a la que pertenece la muestra capturada, así como también el grado de pertenencia de la misma. La red neuronal [13], también utilizada para reconocimiento de patrones visuales [14], [15] y detección de blancos en señales de radar [16], posee una estructura que permite realizar clasificaciones sin una alta demanda de recursos, ofreciendo una buena performance. Esta red no soporta entrenamiento embebido, por lo que los patrones de entrenamiento son utilizados para la generación automática de la arquitectura.

7 Conclusiones y futuros trabajos

Se ha desarrollado un prototipo funcional para determinar en-línea el momento indicado de riego, aplicado al pasto. Se ha trabajado con pasto, aplicable al mantenimiento de grandes extensiones, donde se desea reducir el consumo de electricidad dedicada al bombeo de agua o se desea minimizar el consumo de agua. Es de destacar que la tecnología seleccionada ha sido suficiente como para obtener un dispositivo que permita solucionar el problema planteado.

Por otra parte, el margen de exactitud con el cual hemos llegado a trabajar es de alrededor del 98%, valor más que aceptable para este tipo de aplicaciones.

En este momento se está trabajando para realizar grandes mejoras del sistema, entre ellas: se está estudiando conjuntos de datos de entrenamiento que permitan mejorar la exactitud del sistema, se está estudiando realizar el entrenamiento de la red neuronal orientado a la minimización de riego en otros cultivos (principalmente en olivos), se está diseñando una arquitectura que permita reducir el tamaño y el consumo eléctrico del dispositivo.

Referencias

1. Perspectivas del Medio Ambiente Mundial 2000. PNUMA. Ed. Mundi-Prensa. 2000. Vivendi Environment. Annual Report 2000
2. F.M. de Santa Olalla Mañas, Agua y Agronomía, Ed. Mundi-Prensa, 2005.
3. D. W. Barker and J. E. Sawyer, NITROGEN MANAGEMENT Using Active Canopy Sensors to Quantify Corn Nitrogen Estrés and Nitrogen Application Rate, Published in Agronomy Journal 102:964-971 (2010).
4. J. Bennett, Your Sixth Sense, Corn & Soybean Digest, 2008. http://cornandsoybeandigest.com/equipment/1015_sixth_sense/

