

# Un ambiente Integrado de Ejecución para determinar la Satisfacibilidad de Fórmulas en Forma Normal Conjuntiva

Dar-o Funez, Patricia Roggero, Guillermo Leguizamón

LIDIC

Departamento de Informatica  
Universidad Nacional de San Luis  
Ejercito de los Andes 950  
D5700HHW - San Luis - Argentina  
Tel: 02652-420823 Fax: 02652-430224  
e-mail: {dgfunez,proggero,legui}@unsl.edu.ar

## Abstract

The satisfiability problem (SAT) is a classical  $\mathcal{NP}$ -complete problem of useful application in plenty of computer science areas, electric engineering, and mathematics. In this work we present an integration of all the components of the DPLL system enhanced with Neural Networks (DPLL<sub>NN</sub>) in order to create a user friendly execution environment. One of the main components of DPLL<sub>NN</sub> is an algorithm that is capable of solving some instances of the 3SAT problem, a well-known  $\mathcal{NP}$ -complete problem derived from SAT. DPLL<sub>NN</sub> combines the *Davis-Putnam* rules with neural networks which are capable enough to learn complex problems. The environment proposed allows the user determine the satisfiability of a particular formula either randomly or manually generated. In addition, the environment provides a graphical tree representation of the corresponding assignment values that satisfy that formula (if it can be satisfied).

## Resumen

El problema de satisfacibilidad (SAT), el primero en demostrarse que es  $\mathcal{NP}$ -completo, es fundamental en muchos campos de las ciencias de la computación, la ingeniería eléctrica y matemática. En el presente trabajo se integran todas las componentes del sistema DPLL con Redes Neuronales (DPLL<sub>RN</sub>), para crear un ambiente de ejecución amigable al usuario. Una de las componentes fundamentales del sistema DPLL<sub>RN</sub> consta de un algoritmo que permite resolver algunas instancias del problema 3SAT, un conocido problema  $\mathcal{NP}$ -completo derivado de SAT. El sistema DPLL<sub>RN</sub> combina las reglas de *Davis-Putnam* con redes neuronales (DPRN), las cuales tienen una gran capacidad para aprender problemas complejos. El ambiente propuesto permite al usuario determinar la satisfacibilidad o no de una fórmula en lógica proposicional, permitiéndole ingresar una fórmula cualquiera o generar una aleatoriamente y luego se refleja en un árbol el camino seguido para obtener las asignaciones que hacen verdadera a dicha fórmula si tales asignaciones existen.

## 1. INTRODUCCIÓN

Los problemas  $\mathcal{NP}$ -completos son problemas para los cuales no se conoce un algoritmo de tiempo polinomial determinístico que los pueda resolver. El ejemplo canónico de un problema  $\mathcal{NP}$ -completo es el problema de satisfacibilidad booleana (SAT) [4, 9, 2, 12].

SAT es un problema fundamental en lógica matemática, teoría de computación, inferencia, razonamiento automatizado, ingeniería VLSI, entre otros. Dicho problema se refiere a la tarea de encontrar asignaciones de verdad que hagan a una expresión booleana verdadera. Su importancia reside básicamente en el hecho de que es el primer problema, y uno de los más simples, para el cual se demostró que es  $\mathcal{NP}$ -completo. Además muchos problemas prácticos, tales como demostración automática de teoremas, verificación y detección de fallas de hardware, detección de isomorfismo de grafos, el problema del viajante de comercio, etc [1], son problemas  $\mathcal{NP}$ -completos y se pueden transformar de manera eficiente a SAT. Por lo tanto, buenos algoritmos para SAT son indudablemente de gran utilidad. Dado que es poco probable que se pueda encontrar un algoritmo de tiempo polinomial para resolver SAT, buenas soluciones parecen importantes.

Por lo expuesto anteriormente es que se desarrolló el sistema DPLL\_RN [11] cuya finalidad fue la de tratar de hallar un algoritmo que resuelva instancias del problema 3SAT, combinando uno de los algoritmos prácticos más utilizados en la actualidad, el algoritmo *Davis-Putnam-Logemann-Loveland* (DPLL) [3, 13], cuya eficiencia depende de la elección de una regla de ramificación basada en *Redes Neuronales* (RN) las que permiten realizar en forma heurística la selección de las variables y su correspondiente asignación de valores de verdad. Una de las principales características de las RN en general está dada por su gran capacidad para aprender a resolver problemas complejos y por poseer la habilidad de generalización, dos propiedades importantes a la hora de tratar de resolver instancias del problema de satisfacibilidad. Por otro lado, cabe destacar que una de las principales motivaciones para el desarrollo del sistema DPLL\_RN es que el mismo permite trabajar con distintos tipos de instancias del problema de satisfacibilidad lo que puede ser de gran interés para entender la complejidad del mismo. Sin embargo, el problema fundamental de DPLL\_RN es la falta de un ambiente amigable que permitiera su utilización, sin necesidad de conocer las características propias de la implementación de este sistema, dado que el mismo requiere de una serie de pasos que pueden resultar tediosos cuando se pretende utilizarlo solo para fines prácticos, i.e., obtener asignaciones de verdad para una fórmula. Es por ello que surge la necesidad de desarrollar un ambiente que facilite el uso del sistema DPLL\_RN que oculte al usuario los detalles de implementación del mismo y poder utilizarlo sin tener conocimiento sobre redes neuronales y el algoritmo DPLL, permitiendo de esta manera su utilización por parte de un amplio espectro de usuarios interesados en aprovechar los beneficios de DPLL\_RN.

Este artículo está organizado como sigue. La sección 2 describe brevemente el problema SAT. En la sección 3 se muestra el algoritmo DPLL. La sección 4 presenta las características más relevantes del sistema DPLL\_RN. La sección 5 describe el ambiente integrado de ejecución y por último, en la sección 6 se presentan las conclusiones.

## 2. EL PROBLEMA DE SATISFACIBILIDAD (SAT)

El problema SAT es fundamental en muchos campos de las ciencias de la computación, la ingeniería eléctrica y matemática. Dicho problema fue el primero en demostrarse que es  $\mathcal{NP}$ -completo. El problema de satisfacibilidad consiste en la asignación de valores de verdad a fórmulas en lógica proposicional. El objetivo del problema de satisfacibilidad es determinar si existe una asignación de valores de verdad para las variables booleanas que hagan verdadera a una fórmula.

Una variable booleana es una variable que toma alguno de los valores 0 (falso) o 1 (verdadero).

Las variables booleanas se consideran proposiciones, que son los objetos elementales de la lógica proposicional. El valor de la variable especifica la verdad o falsedad de la proposición. La proposición  $x$  es verdadera cuando a la variable booleana se le asigna el valor 1, cuando el valor asignado es 0 la proposición es falsa. Una *asignación de verdad*<sup>1</sup> es una función que asigna 0 o 1 a toda variable booleana.

Las conectivas lógicas  $\wedge$  (conjunción),  $\vee$  (disyunción) y  $\neg$  (negación) se usan para construir proposiciones llamadas fórmulas bien formadas a partir de un conjunto de variables booleanas.

**Definición 1** Sea  $V$  un conjunto de variables booleanas:

1. Si  $x \in V$ , entonces  $x$  es una fórmula bien formada.
2. Si  $x, y \in V$ , entonces  $(\neg x)$ ,  $(x \wedge y)$  y  $(x \vee y)$  son fórmulas bien formadas.
3. Una expresión es una fórmula bien formada sobre  $V$  solamente si puede ser obtenida a partir de las variables booleanas en el conjunto  $V$  por un número finito de aplicaciones de las operaciones dadas en 2.

Se dice que una fórmula  $u$  satisface una asignación de verdad si los valores de las variables hacen que  $u$  tenga el valor 1. Una *cláusula* es una fórmula bien formada que consiste de una disyunción de variables o la negación de variables. Una variable no negada se llama literal positivo y una variable negada literal negativo. Usando esta terminología, una cláusula es una disyunción de literales, las fórmulas  $x \vee \neg y$ ,  $\neg x \vee z \vee \neg y$  y  $x \vee z \vee \neg x$  son cláusulas sobre el conjunto de variables  $V = \{x, y, z\}$ .

Una fórmula está en *forma normal conjuntiva* si tiene la forma:

$$u = u_1 \wedge u_2 \wedge \dots \wedge u_m$$

donde cada  $u_i$  es una cláusula. Un teorema clásico de lógica proposicional asegura que toda fórmula bien formada se puede transformar en una fórmula equivalente en forma normal conjuntiva. Entonces, de manera rigurosa *el problema de satisfacibilidad* es el problema de decidir si una fórmula en forma normal conjuntiva se satisface por alguna asignación de verdad.

*Ejemplo:* Sea  $V = \{x, y, z\}$  y las fórmulas  $u, v$  y  $w$ :

$$\begin{aligned} u &= (x \vee y) \wedge (\neg y \vee \neg z) \\ v &= (x \vee \neg y \vee \neg z) \wedge (x \vee z) \wedge (\neg x \vee \neg y) \\ w &= \neg x \wedge (x \vee y) \wedge (\neg y \vee x) \end{aligned}$$

las fórmulas  $u$  y  $v$  se satisfacen por la asignación de verdad  $t(x) = T$ ,  $t(y) = F$  y  $t(z) = T$ ; donde  $t : V \rightarrow \{T, F\}$  es la función de asignación de valores de verdad definida sobre el conjunto  $V$ . De esta manera, la primera cláusula en  $u$  es satisfecha por  $x$  y la segunda por  $\neg y$ . La fórmula  $w$  no es satisfecha por  $t$ , es más, no es difícil ver que  $w$  no es satisfecha por ninguna asignación de verdad.

**Definición 2** Una fórmula se dice que está en *3-forma normal conjuntiva*, si cada cláusula contiene exactamente tres literales.

---

<sup>1</sup>También se llama valuación.

Un caso particular derivado del problema SAT es el 3-SAT donde el objetivo del problema 3-SAT es determinar si una fórmula en forma normal conjuntiva (con tres literales por clausula) es satisfacible. Un aspecto muy importante en este contexto es que cualquier fórmula en forma normal conjuntiva puede ser transformada a una fórmula en forma normal conjuntiva con tres literales por clausula. Esto da la fundamentación teórica necesaria para trabajar en DPLL-RN con formulas con tres literales por clausula y dado que el problema 3-SAT presenta una formulación mas sencilla que SAT, es un problema usado comunmente en la bibliografía de teoría de complejidad computacional para mostrar la existencia de otros problemas  $\mathcal{NP}$ -completos [5]. Además, se puede observar, que fórmulas expresadas de manera que todas las clausulas tengan la misma cantidad de variables son, de alguna manera, mas claras.

### 3. ALGORITMO DPLL

Un metodo simple para verificar satisfacibilidad de una fórmula, es generar todos los posibles resolventes, y entonces verificar si se genera la clausula vacía. Davis y Putnam [4] introdujeron un metodo en el cual las variables se eliminan una a una de la fórmula. En cada paso se generan todos los posibles resolventes (basados en la elección de una variable) y entonces se eliminan todas las clausulas que mencionan a aquella variable. Cada paso genera un subproblema con unas pocas variables menos pero, posiblemente, con mas clausulas.

Por ejemplo, dadas dos clausulas  $C_1 = (v \vee x_1 \vee \dots \vee x_p)$  y  $C_2 = (\neg v \vee y_1 \vee \dots \vee y_r)$ , donde  $x_i \neq y_j$ , para  $i = 1, \dots, p$  y  $j = 1, \dots, r$ , el resolvente de  $C_1$  y  $C_2$  es la clausula  $(x_1 \vee \dots \vee x_p \vee y_1 \vee \dots \vee y_r)$ , esto es, la disyunción de  $C_1$  y  $C_2$  sin  $v$  y  $\neg v$ . El resolvente es una consecuencia lógica de la conjunción del par de clausulas. La resolución es el proceso de generar repetidamente resolventes desde las clausulas originales y los resolventes previamente generados, hasta que la clausula nula sea generada o no se puedan crear mas resolventes. En el primer caso la fórmula es no satisfacible y en el ultimo caso es satisfacible.

El algoritmo DPLL [3, 13, 12] es una variación al algoritmo original propuesto por Davis y Putnam (DP), dicha variación es mas eficiente que el metodo original para propósitos prácticos. DPLL usa una *regla de splitting*, la cual permite reemplazar al problema original por dos subproblemas mas pequeños, y además, permite determinar cual es la variable a seleccionar. Esencialmente, el algoritmo es una búsqueda *depth-first con backtracking* a través de las asignaciones de verdad (parciales). Este algoritmo tiene un fuerte crecimiento exponencial. En el peor caso, para una fórmula no satisfacible, DPLL buscara a través de todas las asignaciones de verdad que puedan ser hechas.

Dos heurísticas son aplicadas durante este proceso (ver Algoritmo 1) con la idea de podar el espacio de búsqueda. Estas, son la *regla del literal puro* y la *cláusula unitaria*.

- La regla del literal puro se aplica cuando una variable aparece con un unico valor de verdad en todas las clausulas aun no satisfechas. En este caso, se asigna un valor de verdad a dicha variable de manera que todas las clausulas involucradas sean satisfechas. Este es un procedimiento altamente efectivo en la búsqueda.
- Si alguna variable ocurre en la fórmula corriente en una clausula de longitud 1, entonces la regla de la cláusula unitaria se aplica. El literal se selecciona y se le asigna un valor de verdad de manera que la clausula respectiva sea satisfecha. La aplicación repetida de la regla unitaria comunmente se conoce como *Unit Propagation* o *Boolean Constraint Propagation (BCP)*.

El algoritmo DPLL trabaja por prueba y error, generalmente se puede observar la secuencia de pasos, utilizando un árbol de búsqueda, que se forma de la siguiente manera:

---

**Algorithm 1** Algoritmo DPLL (con heurísticas) en pseudocódigo

---

Procedure DPLL (CNF formula: $\varphi$ )

```
if ( $\varphi$  es vacía) return sí
else if (hay una clausula vacía en  $\varphi$ ) return no
else if (hay un literal puro  $v$  en  $\varphi$ ) return DPLL( $\varphi(v)$ )
else if (hay una clausula unitaria  $\{v\}$  en  $\varphi$ ) return DPLL( $\varphi(v)$ )
else seleccionar una variable  $v$  mencionada en  $\varphi$ 
  if DPLL( $\varphi(v) = sí$ ) then return sí
  else return DPLL( $\varphi(\neg v)$ )
```

end

---

1. Un nodo corresponde a la elección de una variable. Dependiendo de este nodo, DPLL toma una de dos acciones posibles y esto se refleja con un descendiente (arco) en el árbol.
2. A partir de un arco, se extraen todas las implicaciones lógicas que se derivan de la última elección tomada.
3. Se vuelve a 1, a menos que encuentre una solución o llegue a una contradicción. En este último caso, se hace *backtracking* hasta el nodo incompleto más cercano (con un único arco descendiente), invierte el valor de la variable y vuelve a 2; si todos los nodos tienen sus dos arcos descendientes, se determina la satisfacibilidad de la fórmula.

En la tabla 1 se muestra la ejecución del algoritmo para un ejemplo particular. Una de las columnas incluye la representación gráfica del árbol de búsqueda.

**Paso 0:** la instancia consiste de 5 cláusulas que involucran 4 variables, a las cuales se les puede asignar el valor verdadero ( $T = \text{True}$ ) o falso ( $F = \text{False}$ ). Dado que es el paso inicial, el árbol de búsqueda es vacío.

**Paso 1:** en este paso DPLL selecciona aleatoriamente una variable, entre las cláusulas más cortas y le asigna un valor para que satisfaga la cláusula a la cual pertenece, por ejemplo  $w = T$ . Entonces se agrega un nodo y un arco, los cuales representan la variable seleccionada ( $w$ ) y su valor de verdad (en este caso  $T$ ) respectivamente.

**Paso 2:** se extraen, a partir de la última elección, las implicaciones lógicas: las cláusulas que contienen la variable  $w$  se satisfacen y son eliminadas, las cláusulas que incluyen  $\neg w$  son simplificadas, y el resto de las cláusulas se mantiene sin modificaciones. Si ninguna cláusula unitaria (es decir con una sola variable) existe, entonces se debe seleccionar una nueva variable.

**Paso 3:** en este punto toma lugar la regla de división (*splitting*), por lo tanto otro nodo y otro arco se agregan al árbol.

**Paso 4:** como en el paso 2, pero en este punto existen cláusulas unitarias, entonces las variables que ellas contienen deben ser fijadas de manera adecuada (esto es lo que se denomina propagación).

**Paso 5:** la propagación de la cláusula unitaria resulta en una contradicción, por lo tanto, el camino corriente en el árbol de búsqueda se marca con una  $C$ .

**Paso 6:** el algoritmo DPLL retrocede hasta la última variable en la que se produjo una división (*split*) ( $x$ ), invierte su valor, es decir le da el valor  $F$  y crea un nuevo arco.

**Paso 7:** se realiza lo mismo que en el paso 4.

**Paso 8:** La propagación de la cláusula unitaria elimina todas las cláusulas, esto significa que se encontró una solución  $S$ .

En este ejemplo se muestra como DPLL encuentra una solución para una instancia satisfacible. Para una instancia no satisfacible, la no satisfacibilidad se prueba cuando al retroceder (paso 6) no es



Paso	Cláusulas	Árbol de búsqueda
0	$w \vee \neg x \vee y$ $\neg w \vee x \vee z$ $\neg w \vee \neg x \vee \neg y$ $\neg w \vee \neg x \vee y$ $x \vee y \vee \neg z$	
1	split: $w = T$	
2	$x \vee z$ $\neg x \vee \neg y$ $\neg x \vee y$ $x \vee y \vee \neg z$	
3	split: $x = T$	
4	$\neg y$ $y$	
5	propagación: $y = F$ $y = T$ contradicción	
6	volver al estado 3: $x = F$	
7	$z$ $y \vee \neg z$	
8	propagación: $z = T$ $y = T$ solución: $w = T, x = F, y = T, z = T$	

Tabla 1: Ejemplo de la resolución de una instancia de 3-SAT utilizando el algoritmo DPLL.

posible ninguna acción, es decir, todas las variables tomaron los valores  $T$  y  $F$ . En este caso todos los nodos en el árbol de búsqueda normal tendrán sus dos arcos descendientes y las hojas, rotuladas con  $C$  (una contradicción).

#### 4. DPLL Y REDES NEURONALES (DPLL\_RN)

La idea central de DPLL\_RN es que a partir de un conjunto de fórmulas satisfacibles generadas aleatoriamente, se genera un conjunto de patrones que corresponden a las asignaciones óptimas de valores a variables que satisfacen dichas fórmulas. Luego, se entrena una red neuronal con dichos patrones y finalmente se ejecuta el algoritmo DPRN para un conjunto de fórmulas satisfacibles y no satisfacibles generadas aleatoriamente. En la figura 1 se puede observar un esquema gráfico con las distintas componentes del sistema.




Figura 1: Componentes del sistema DPLL\_RN

El algoritmo DPRN, que es una parte central del sistema, puede ser considerado un algoritmo híbrido ya que se basa en el algoritmo DPLL aumentado con el poder de las redes neuronales [8, 11]. DPRN tiene características propias que lo hacen interesante, dado que el mismo está basado en el algoritmo DPLL pero haciendo uso de una red neuronal para que decida cuál es la variable que debe ser seleccionada en cada caso y con qué valor de verdad. De esta manera, DPRN permite determinar la satisfacibilidad y no satisfacibilidad de fórmulas que no se encuentran en el conjunto de entrenamiento debido al poder de generalización de las redes neuronales.

Las etapas involucradas en la aplicación del sistema DPLL\_RN son:

- Generación aleatoria de fórmulas en forma normal conjuntiva (CNF): esta etapa consiste en la generación aleatoria de las fórmulas utilizando el programa `mkcnf` [6].

- Obtención de las asignaciones que hacen verdaderas las fórmulas: el conjunto de asignaciones de verdad que satisfacen las formulas se selecciona usando un algoritmo de búsqueda. La selección esta basada en las reglas que usa el algoritmo DPLL, de manera que es un algoritmo exhaustivo que usa la regla del literal puro y la clausula unitaria. Este algoritmo permite obtener todas las asignaciones posibles de valores para todas las variables y en todos los ordenes posibles, y a partir de allí se seleccionan los caminos de longitud mínima que satisfacen las fórmulas, esto es, los caminos de longitud mínima en el arbol de búsqueda generado por este algoritmo.
- Determinación del conjunto de patrones de entrenamiento: el conjunto de entrenamiento se genera en base a las asignaciones de verdad obtenidas con el algoritmo mencionado en el item anterior, en donde por cada paso, se genera un conjunto de patrones analizando las decisiones que se deben tomar en cada punto.
- Entrenamiento de la red neuronal: una vez obtenidos los patrones de entrenamiento, se entrena con el simulador *Stuttgart Neural Networks Simulator* (SNNS) [10], una red neuronal de multiples capas con conexiones hacia adelante, utilizando el algoritmo *backpropagation* con momento, con los parametros estandar para este tipo de algoritmo. El numero de unidades de entrada y de salida es el doble del numero de variables.
- Ejecución del algoritmo DPRN: en la última etapa se ejecuta el algoritmo DPRN, utilizando como entrada un conjunto de fórmulas satisfacibles y no satisfacibles no utilizado para el entrenamiento, dicho algoritmo determina la satisfacibilidad o no de las fórmulas dadas.

## 5. AMBIENTE DE EJECUCIÓN

Un ambiente de ejecución se puede utilizar para describir el contexto en el cual se ejecutan ciertas tareas. Este trabajo en particular permite definir el contexto en el cual es posible utilizar el sistema DPLL-RN, de una manera amigable y haciendo uso de los beneficios provistos por el lenguaje de programación Java (e.g. posibilidades de desarrollo de aplicaciones web, etc.). El ambiente permite al usuario la posibilidad de elegir entre dos opciones para el ingreso de la fórmula, una de ellas es que el mismo genere una fórmula de forma aleatoria y la otra opción es que el usuario ingrese la fórmula que el desee en forma manual. El ambiente entonces va a mostrar las asignaciones de verdad que hacen verdadera la fórmula, utilizando un arbol para tal fin. La forma gráfica del mismo permite que el usuario conozca las asignaciones de verdad. En el caso que la fórmula no sea satisfacible el ambiente muestra un arbol vacío.

### 5.1. Módulos que conforman el Ambiente

Obtención del conjunto de redes neuronales

Aquí se obtienen las redes neuronales necesarias para ejecutar el algoritmo DPRN del sistema DPLL-RN. Este conjunto de redes neuronales consta de una red para 3 variables, para ser utilizada cuando se requiere determinar la satisfacibilidad de una fórmula de 3 variables, una para 4 variables, y así siguiendo, cabe destacar que se podrán tener más de una RN en cada caso particular, y seleccionar cualquiera de ellas. Es decir, es necesario contar con un pool de redes neuronales entrenadas según lo descrito en la sección 4, para ser utilizadas cuando el algoritmo DPRN lo requiera.

### Sub-sistema DPRN (del sistema DPLL\_RN)

El programa DPRN que forma parte del sistema DPLL\_RN utiliza un archivo con la fórmula a analizar y una RN de las obtenidas según se explica en el punto anterior. Cuando un usuario ingresa una fórmula para ser analizada, con el número de variables de la misma determina cual red va a utilizar y abre el archivo de la red que corresponda, de aquí se extrae toda la información de la red que necesita el algoritmo.

### Generador de fórmulas aleatorias

El ambiente tiene una opción de generar fórmulas de forma aleatoria y este informa sobre la satisfacibilidad o no de la misma. Por tal motivo se necesita de un módulo que realice la tarea de generar una fórmula de forma aleatoria en CNF, que también es parte de este ambiente.

### Manejo de las fórmulas

Una de las opciones del ambiente es que la fórmula sea generada de forma aleatoria. En este caso se solicita que se ingresen la cantidad de variables, la cantidad de cláusulas que debe contener la fórmula y la semilla que debe ser utilizada por el generador aleatorio. La otra opción es que el usuario ingrese la fórmula que el desee, en este caso se solicita la cantidad de variables, la cantidad de cláusulas y la fórmula cuyas variables se denotan con letras mayúsculas, comenzando desde la A. El formato de la fórmula puede contener los operadores lógicos ( $\vee$  y  $\wedge$ ) y los parentesis que necesite. Sin embargo, estos últimos son optativos dado que el sistema trabaja con fórmulas en forma normal conjuntiva.

### Interface propiamente dicha

Cuando el ambiente se inicia muestra las dos opciones de ingreso de fórmulas. Una es el ingreso manual y la otra el aleatorio.

## 5.2. Un ejemplo utilizando el ambiente de ejecución

Cuando se inicia la ejecución del ambiente el usuario va a ver una pantalla con las dos opciones para el ingreso de fórmulas. Una es el ingreso manual y la otra el aleatorio. A continuación se muestra un ejemplo completo del funcionamiento del ambiente.

En la figura 2 se puede ver la primer pantalla que muestra el ambiente.




Figura 2: Elección de ingreso manual de una fórmula

Como se muestra en la pantalla luego de la eleccion de la opcion tiene la posibilidad de *salir* del ambiente o *aceptar*, y continuar con el ingreso de la fórmula. Cuando se presiona el botón de *aceptar* se muestra la pantalla de la figura 3.




Figura 3: Ingreso de una fórmula

En esta pantalla se solicitan tres datos que son:

- Cantidad de variables de la fórmula (la fórmula a ingresar tiene 3 variables).
- Numero de clausulas (la fórmula a ingresar tiene 5 clausulas).
- La fórmula en CFN: aquí se debe ingresar la fórmula para analizar la satisfacibilidad. Se pueden omitir los parentesis y los operadores lógicos ( $\vee$  y  $\wedge$ ). En este caso se ingresó la siguiente fórmula omitiendo dichos operadores lógicos y parentesis:

$$\neg A \neg B \neg C B \neg A C \neg C \neg B A \neg A B \neg C \neg B A C$$

que se corresponde a la siguiente fórmula :

$$(\neg A \vee \neg B \vee \neg C) \wedge (B \neg \vee A \vee C) \wedge (\neg C \vee \neg B \vee A) \wedge (\neg A \vee B \vee \neg C) \wedge (\neg B \vee A \vee C)$$

La pantalla de la figura 4 tiene como finalidad mostrar en forma gráfica, a través de un árbol, las asignaciones de verdad que satisfacen la fórmula ingresada. Dicho árbol se interpreta de la siguiente manera: cada variable se muestra con un rectángulo con su nombre y este puede tener dos ramas, la rama de la derecha significa que a la variable se le ha asignado el valor *verdadero* y la rama de la izquierda significa que tiene asignado el valor *falso*. De cada nodo siempre saldrá una rama, porque significa que ese es el valor de verdad que debe tener asignado para poder satisfacer la fórmula (en el caso que la fórmula sea satisfacible).

El usuario puede extraer la asignaciones de verdad que hacen verdadera la fórmula visualizando el árbol como sigue. Comienza el recorrido del árbol desde la raíz, cada nodo tiene el nombre de la variable y obtiene su asignación con solo ver cual es la rama que sale del nodo. Luego se sigue la rama hasta otro nodo y se procede de la misma manera hasta que se haya examinado todos los nodos de dicho árbol. En el caso de nuestro ejemplo, con solo visualizar el árbol se puede obtener las siguientes asignaciones para las variables,  $t(B) = F$  y  $t(A) = F$ , las cuales satisfacen la fórmula ingresada. Sobre la variable  $C$  no aparece ninguna asignación de verdad, lo significa que puede tener asignado cualquier valor de verdad.




Figura 4: Resultado de una asignación de verdad  $t(A) = F$  y  $t(B) = F$ .

## 6. CONCLUSIONES

La idea central del presente trabajo fue la de desarrollar un ambiente de ejecución que permita utilizar las distintas componentes del sistema DPLL\_RN, sin necesidad de que el usuario tenga que conocer los detalles de la implementación de dichas componentes, y que además, provea un entorno de manera que la interfase con el usuario sea amigable. Por otro lado, también se obtuvo un algoritmo híbrido basado en el algoritmo DPLL, el cual es uno de los más usados para propósitos prácticos, combinado con las capacidades de aprender y generalizar de las redes neuronales. A partir de aquí y de los resultados obtenidos [8, 11] se puede esperar que esta herramienta sea un punto de comienzo para lograr resultados más robustos, es decir, trabajar con una cantidad mayor de variables, hecho fundamental en el crecimiento exponencial del problema SAT, y por ende en la complejidad de los algoritmos necesarios para resolver instancias de este problema. Finalmente, es importante destacar que en la bibliografía existente no se ha propuesto ningún algoritmo con las características que tiene el algoritmo DPRN [1, 7].

## REFERENCIAS

- [1] Carlos Ansoategui and Felip Manyà. An introduction to satisfiability algorithms. *Revista Iberoamericana de Inteligencia Artificial*, (20), 2004.

- [2] Stephen A. Cook and David G. Mitchell. Finding Hard Instances of the Satisfiability Problem: A Survey, 1997.
- [3] M. Davis, G. Logemann, and D. Loveland. A machine program for theorem-proving. *Communications of the ACM*, (5):394–397, 1962.
- [4] Martin Davis, Ron Sigal, and Elaine Weyuker. *Computability, Complexity and Languages*. Academic Press, 2nd edition, 1994.
- [5] M R. Garey and D. S. Johnson. *Computers and Intractability : A Guide to the Theory of NP-Completeness (Series of Books in the Mathematical Sciences)*. 1979.
- [6] Allen Van Gelder. Mknf formulas generator. *University of California, Santa Cruz*.
- [7] J. Gu, P. W. Purdom, J. Franco, and B. W. Wah. Algorithms for satisfiability (sat) problem: A survey. *DIMACS Volume Series on Discrete Mathematics and theoretical Computer Science*, (35):19–151.
- [8] Carlos Kavka and Patricia Roggero. Solving 3SAT Problems using Neural Networks. *Artificial Intelligence an Applications*, pages 431–435, September 2001.
- [9] Christos Papadimitriou and Kenneth Steiglitz. *Combinatorial Optimization - Algorithms and Complexity*. Dover Publications, 1998.
- [10] Institute Parallel and Distributed High Performance Systems. Stuttgart neural network simulator user's manual. *Stuttgart University, Germany*.
- [11] Patricia Roggero. *Aplicación de Técnicas de Inteligencia Computacional para Resolver Instancias del Problema de Satisfacibilidad*. PhD thesis, Departamento de Informatica - UNSL, Mayo 2005.
- [12] Andrew Slater. *Investigations into satisfiability search*. PhD thesis, Computer Sciences Laboratory, Research School of Information Sciences and Engineering, ANU, 2004.
- [13] W. M. Spears and K. A. De Jong. Davis Putnam Logemann and Loveland Algorithms. pages 118–121, 1990.