

Applications of artificial immune system algorithm

Aplicaciones del algoritmo del sistema inmunológico artificial

José Carlos¹, Maita Díaz², María Salas³

¹Department of Mathematics, Universidad de Antioquia, Bolivia

²Department of Mathematics, Universidad del Valle, Cali, Bolivia

³Department of Mathematics, Universidad Católica Boliviana, Bolivia

Abstracto

Un sistema inmunológico, uno de los sistemas biológicos más intrincados, se ha utilizado como metáfora de la computación inteligente en una variedad de dominios. El Sistema Inmunológico Artificial ha sido considerado como una familia de técnicas originadas en la comunidad de la inmunología.

Palabras clave: sistema inmunológico artificial, optimización, modelo matemático, minería de datos

Abstract

An immune system, one of the most intricate biological systems, has been used as a metaphor for intelligent computation in a variety of domains. Artificial Immune System has been considered as a family of techniques originated from the community of immunology.

Keywords: Artificial immune system, optimization, mathematical model, data mining

1.Introducción

Un sistema inmunológico, uno de los sistemas biológicos más intrincados, se ha utilizado como metáfora de la computación inteligente en una variedad de dominios[1]. El sistema inmunológico artificial (AIS) tiene ha sido considerada como una familia de técnicas originadas en el comunidad de inmunología. Como componente importante de el AIS, las redes inmunes artificiales se basan en el principios del comportamiento tanto de las células B como de las células T en el sistema inmunológico biológico[2]. La célula B es una parte integral de la sistema inmunitario. Mediante un proceso de reconocimiento y estimulación, las células B pueden clonarse y mutar para producir una diverso conjunto de anticuerpos en un intento de eliminar la infección del cuerpo. La célula T tiene dos tipos[3]. Uno regula y controla la fuerza de la respuesta inmune, y la otra directamente destruye las células que tienen antígenos específicos. Tanto la B Las células y las células T se han empleado ampliamente para resolver una amplia una variedad de problemas de ingeniería, como la detección de anomalías y procesamiento de datos. Este documento tiene como objetivo ofrecer una descripción concisa sobre los modelos de redes inmunes artificiales, incluida su teoría, estructuras y aplicaciones[4].

El resto de nuestro trabajo se organiza de la siguiente manera. Sección proporciona una breve reseña de la inmunología relevante[5]. Sección analiza varios modelos típicos de redes inmunes artificiales. Las aplicaciones de estas redes inmunes artificiales en minería de datos, clasificación asociativa, reconocimiento de patrones y optimización de funciones se presentan en la Sección. Finalmente, La sección 5 concluye este artículo con algunas observaciones y conclusiones.

2.Revisión de literature

Un sistema inmunológico natural tiene un "cazar y destruir" muy complejo mecanismo que trabaja a nivel celular dentro de nuestro cuerpos. Tiene la notable capacidad de aprender sobre sustancias extrañas (patógenos) que ingresan al cuerpo y responden a ellos produciendo los anticuerpos, que pueden atacan los antígenos asociados con los patógenos[6]. Generalmente, el sistema inmunológico humano consiste en el antígeno- presentando células, linfocitos y anticuerpos. Los linfocitos son un tipo de glóbulos blancos, o más específicamente, Linfocitos B y linfocitos T[7]. Estas células ayudan en reconocer y destruir sustancias específicas. Una célula B contiene los anticuerpos en su superficie, que pueden reconocer el antígenos que invaden el cuerpo humano. Las regiones de Las moléculas a las que se puede unir el paratopo se denominan epítomos[8]. La identificación del antígeno se logra mediante el complemento coincidencia entre su paratopo y epítopo, comparable para "bloquear y llave". La figura 1 ilustra cómo un antígeno- presenta procesos celulares y presenta un antígeno[9]. Células T puede interactuar con el antígeno con la ayuda del antígeno presentando y mayores moléculas complejas de histocompatibilidad. Más precisamente, ilustra que una vez que un antígeno Presenting Cell (APC) encuentra el antígeno, internaliza el antígeno, y lo fragmenta en péptidos antigénicos[10]. En , piezas de estos péptidos se incorporan a las moléculas MHC, estos péptidos se muestran en la superficie del célula. La célula T reconoce e interactúa con este péptido. Complejo de moléculas MHC que utiliza su propio receptor. Nota que las células T

no interactúan con el antígeno directamente. En lugar se adhieren a la célula mostrando complejos de antígenos extraños sobre la base de una molécula de MHC[11].

Un anticuerpo reconoce y elimina solo un tipo específico de antígenos. La porción clave del antígeno reconocido por el anticuerpo se llama epítipo, un determinante de antígeno, como se muestra. El paratope es la porción del anticuerpo que corresponde a un cierto tipo de antígenos. Cuando un anticuerpo fusiona un antígeno a través del epítipo y el paratope, puede atacar este antígeno[12].

El sistema inmunológico humano mantiene un recuerdo de las infecciones. de modo que si alguna vez se expone al mismo antígeno, una se puede provocar una respuesta contra la infección[13]. En otras palabras, la respuesta inmune secundaria ocurre, cuando el mismo antígeno de hecho se encuentra. Se caracteriza por un raperio y producción más abundante del anticuerpo, que resulta de la respuesta primaria.

En esta sección, algunas redes inmunes artificiales representativas se introducen modelos. Discutiremos la teoría de estos modelos, estructuras y algoritmos de aprendizaje en detalle[14].

El sistema inmunológico artificial de recursos limitados (RLAIS) se basa en el trabajo del AIS básico. Como sabemos, el Los AIS consisten en un conjunto de células B, enlaces entre sí a través de sus niveles de estimulación y operaciones de clonación y mutación realizado en estas células B. El AIS puede agruparse patrones similares en los datos de entrenamiento presentados[15]. Esta red de Las células B representan grupos con enlaces de afinidad. Sin embargo, varios parámetros críticos deben configurarse manualmente para inicialización: número de iteraciones, la afinidad de la red Umbral (NAT) y tasa de mutación, que se explican como sigue.

El número de iteraciones en las que se presentan los datos de entrenamiento. a un sistema de aprendizaje no es fácil de elegir. No existe una correlación directa entre el número de iteraciones y valor de vinculación. Sin embargo, algunas experiencias las observaciones son claras: a). cuantas más veces el conjunto de entrenamiento sea presentado a la red inmunitaria artificial, más tiempo lleva para que la red converja. De hecho, hay un exponencial crecimiento en el tamaño de la red, independientemente del conjunto de entrenamiento, tasa de mutación y NAT. si)[16]. No tenemos una frontera definida línea entre presentar los datos de entrenamiento de una manera insuficiente o número excesivo de veces. Demasiadas presentaciones del Los datos de entrenamiento pueden conducir a una gran red que es difícil interpretar. La selección adecuada de este parámetro de inicialización es claramente vital en el entrenamiento exitoso del AIS. La de rastrea el procedimiento de evolución del RLAIS con el conjunto de datos Iris como muestras de entrenamiento. Figura muestra la red resultante después de dos iteraciones. Es claramente demuestra un grupo separado del grupo principal. La ilustra la red después de cinco iteraciones, desde que es casi imposible observar cualquier estructura de red[17].

Si la afinidad entre dos células B es menor que la NAT, una se crea un vínculo entre ellos. De hecho, el NAT influye directamente en el enlace de la red, y debe ser elegido como un valor pequeño, por ejemplo, 0,1, que puede disminuir la conectividad potencial del AIS y, por lo tanto, separar la los datos de entrenamiento de forma más eficiente que si tuvieran valores mayores.

Dado que la tasa de mutación crea una representación diversa de los datos de entrenamiento, puede reducir la conectividad en el AIS. Si la tasa de mutación es mayor, producirá una red con menos células B. La figura 4 muestra el crecimiento de la red vinculación durante el tiempo de entrenamiento con una tasa de mutación del 10% en el Conjunto de datos de iris.

3. Discusión

La principal diferencia entre un AIS y un RLAIS es la eliminación del número de veces que se presenta el conjunto de datos de entrenamiento a la red. El RLAIS no requiere configuración el número de ciclos de formación de antemano, pero todavía puede ofrecer una estrategia de control de la población más eficaz. Estas mejoras se deben al despliegue del Reconocimiento Artificial Bola (ARB). El ARB es una representación de cierto número de células B idénticas, porque las células B individuales ya no son representado explícitamente en el RLAIS. El RLAIS tiene un grupo de ARB, así como vínculos entre ellos. Todas las ARB compiten para representar las células B dentro del RLAIS sobre la base de sus niveles de estimulación. Cuanto mayor sea el nivel de estimulación de ARB, cuantas más células B pueda representar. Una vez que un ARB no representa ninguna célula B, se elimina de la red. En efecto, el objetivo del mecanismo de mutación es crear nuevos ARB que puede ajustarse mejor a los datos de entrenamiento. A medida que se crean nuevos ARB, algunos de ellos coinciden satisfactoriamente con los datos de entrenamiento, mientras que otros no lo son. Estos últimos están menos estimulados por la datos de entrenamiento y red, y finalmente se eliminarán del RLAIS. Se obtiene el tamaño "base" de la red después de varias iteraciones de entrenamiento. Por tanto, el sobreentrenamiento no es un problema grave en el RLAIS. La

explosión demográfica el crecimiento se puede eliminar mediante el nuevo control de población anterior esquema. Claramente, en comparación con la población AIS crecimiento, no existe crecimiento exponencial en el RLAIS. Adicionalmente, en lugar de volver a calcular el NAT al final de cada época de entrenamiento en el AIS, la mantenemos constante durante todo el todo el proceso de aprendizaje en el RLAIS.

El RLAIS también se puede utilizar como una base sólida para aprendizaje: los datos de entrada nunca antes vistos se presentan al RLAIS para permitir que se aprendan nuevos patrones sin adversamente afectando esos patrones ya aprendidos. Desafortunadamente, hay Hay algunos problemas sin resolver en el diseño de nuestro RLAIS. por ejemplo, eligiendo el número de células B que el RLAIS debe asignar es un factor importante. Si hay demasiados recursos seleccionados, la red será demasiado grande y poco representativo, mientras que muy pocos recursos pueden resultar en algunos Patrones no capturados. La referencia propone un nuevo Sistema inmunológico artificial autoestabilizante (SSAIS) para tratar con este inconveniente. El SSAIS se diferencia del RLAIS en que no hay una cantidad fija de recursos para ser centralizada distribuidos entre los ARB. El concepto de recursos sigue siendo utilizado, pero de forma alterada. En SSAIS, los recursos son manejado localmente por cada ARB. El ARB puede aumentar su propio asignación de recursos, cuando registra la mayor estimulación para una muestra de datos entrantes.

La aiNet es un tipo emergente de AIS inspirado en el La teoría de la red inmunitaria fue propuesta por primera vez por Jerne. Se desarrolla en base a las ideas y conceptos de tres teorías: la teoría de la red inmunizada, la selección clonal principio y principio de maduración por afinidad. El principal El papel de esta red inmunitaria artificial es realizar datos compresión siguiendo la selección clonal, así como principios de maduración por afinidad. La teoría de la red inmunológica hipotetiza las actividades de las células inmunes, la aparición de memoria y discriminación entre nuestras propias células (conocido como self) e invasores externos (conocidos como no-self). La aiNet modelo consta de un grupo de células, a saber, anticuerpos, interconectados por enlaces con fortalezas de conexión asociadas. los Los anticuerpos aiNet representan las imágenes internas de la red del patógenos (patrones de entrada) a los que están expuestos. los las conexiones entre estos anticuerpos determinan sus interrelaciones con proporcionar un grado de similitud entre ellos en el espacio métrico dado. Cuanto más cerca estén los anticuerpos, más similares son. Este enfoque da como resultado un anticuerpo red que puede reconocer los antígenos (conjunto de datos de entrada) con una generalidad ajustable.

El procedimiento de aprendizaje de aiNet se puede dividir en dos principales pasos. El primero corresponde a la selección clonal interacciones de maduración de principio e afinidad, donde el Los anticuerpos (Ab) sufren la clonación y la mutación para reconocer los antígenos (Ag). Esta etapa es realmente similar a el ALgoritmo de selección CLONal (CLONALG) propuesto originalmente por de Castro y von Zuben. Los datos de entrenamiento sin procesar el conjunto es explorado y comprimido por la aiNet que conduce a un red de anticuerpos que extrae la información más relevante a partir de los datos para fines de agrupación. El segundo paso de la aiNet incluye las interacciones e introducción de la red inmunológica de diversidad. El árbol de expansión mínimo (MST) es construido sobre la red de anticuerpos, y sus bordes inconsistentes son identificado y eliminado, que puede transformar la red (datos) separación en grupos.

En general, la aiNet está desarrollada para responder a las siguientes preguntas importantes: hay una gran cantidad de redundancia dentro del conjunto de datos de entrenamiento y, si lo hay, ¿cómo podemos reducir ¿eso? ¿Hay subgrupos intrínsecos a los datos? Cuántos ¿Hay grupos en el conjunto de datos de entrada? ¿Cuál es la estructura de la distribución espacial de estos datos? ¿Cómo podemos generar reglas de decisión para clasificar muestras nuevas [8]? sin embargo, el Los principales inconvenientes de aiNet, como se señala en, son las gran cantidad de parámetros y procesamiento dependientes de la aplicación sobrecarga de cada iteración.

La aiNet puede considerarse como una evolución artificial red inmune, porque las estrategias de evolución basadas en la variación genética y la selección dentro de una población de Los individuos se utilizan para controlar la dinámica de la red y plasticidad. La referencia propone que aiNet es capaz de detectando las soluciones óptimas. Combinado con la constante criterio de módulo, se ha empleado para la ciega óptima Ecuación IIR. Además, la aiNet también es un conexionista sistema, en el que una matriz de fuerzas de conexión es definido para medir las afinidades entre las células de la red. los El algoritmo de aprendizaje apunta a construir un conjunto de memoria que pueda reconocer y representar la organización estructural de la datos de entrenamiento. Especialmente, los controles de umbral de supresión el nivel de especificidad de las células, precisión de agrupamiento, así como plasticidad de la red.

INet es un marco general para simular lo natural redes inmunes y una descripción más detallada de cómo desarrollar la AIS. Utiliza los principios esenciales del AIS, como negociación autónoma de políticas y reconfiguración del sistema facilidad, para la comunicación. La iNet sirve como información infraestructura, y se

puede aplicar para explorar mecanismos relacionados. Además, ayuda a investigar una familia de aplicaciones basadas en las redes inmunes artificiales. Tal como lo conocemos, Los marcos y patrones de aplicación pueden mejorar la reutilización técnicas, reducir el costo de desarrollo y mejorar la calidad de aplicaciones. Los componentes reutilizables dentro de iNet son diseñado con varios patrones de software. Por lo tanto, iNet puede mostrar explícitamente a los desarrolladores sus intenciones de diseño y extensión puntos, con los que pueden adaptar eficazmente sus propias aplicaciones. Más precisamente, está diseñado para permitir adecuada personalización de varias estrategias para construir el redes inmunes artificiales, por ejemplo, topología de red y red control de dinámica. INet contiene cuatro paquetes principales: Visualización de GUI, gestión de gráficos, inmunocomponente gestión y persistencia e intercambio, como se ilustra.

La elección de un modelo AIS, incluida su expresión, emparejamiento, entrenamiento, evaluación y varios parámetros de control, En general, está predeterminado por expertos basados en su experiencia en el espacio de problemas hipotéticos. El modelo es siguiente iterativamente ajustado hasta que se haya obtenido un resultado satisfactorio logrado tanto en entrenamiento como en pruebas. Si no hay o hay pocos mejora durante este proceso, es necesario recurrir a otros modelos. Debido a la experiencia limitada de los expertos individuales, No es trivial definir un modelo AIS robusto para detectar todos los posibles objetos.

Plataforma Integrada de Sistemas inmunes artificiales (IPAisys) basados en el detector modo de población para abordar los problemas antes mencionados. En esta plataforma, un grupo de prototipos de modelos se integran en una marco unificado, donde la estructura del modelo puede ser regularizado automáticamente utilizando el resultado de la formación y pruebas, como la llamada "presión". Un algoritmo autorregulador es desarrollado con el uso de la biblioteca de modelos para lograr el óptimo modelos multi-AIS mediante configuración dinámica. Por lo tanto, esta plataforma es flexible e inteligente, porque es capaz de elegir una combinación óptima de diferentes modelos para evalúe cooperativamente cada caso desconocido.

En los últimos años, ha habido numerosos modelos AIS propuesto para diferentes aplicaciones previstas. A. Iqbal y M. A. Maarof sugiere un modelo de APC artificial para el peligro codones de datos susceptibles. S. Stepney, R. E. Smith, J. Timmis presentan que los algoritmos bioinspirados se desarrollan mejor y analizado en el contexto de una multidisciplinariedad marco conceptual que proporciona un sofisticado modelos y principios analíticos bien fundamentados. UNA marco en el contexto de los modelos de red AIS también es descrito.

Durante la última década, las redes inmunes artificiales han se ha aplicado con éxito a una gran variedad de ingeniería áreas, como minería de datos, predicción de series de tiempo, patrones reconocimiento, optimización, detección de fallos, ordenador seguridad y control de procesos. En esta sección, algunos ejemplos de estas aplicaciones se demuestran y discuten. También presentaremos nuestro trabajo sobre las aplicaciones de agrupamiento. del AIS. Ilustra que nuestro algoritmo de agrupación en clústeres basado en AIS es mejor que el método de agrupación en clúster de uso común, K-significa.

La Red Inmune Artificial (AINE) es una especie de AIS desarrollado para el análisis de datos y el descubrimiento de patrones. Eso emplea algunas metáforas de alto nivel extraídas de la naturaleza sistema inmunológico, por ejemplo, las células B son capaces de reconocer patógenos (reconocimiento antigénico), las células B similares están vinculadas juntos y estos enlaces forman una red de células B (inmunes teoría de redes), se realizan operaciones de clonación y mutación en células B (selección clonal e hipermutación somática), y un cierto número de células B se puede representar mediante un ARB único. El AINE puede mostrar claramente las relaciones entre los nodos en su estructura de red topológica.

La AINE ha sido investigada en el conocido Datos de Fisher's Iris. Después de 20 iteraciones, la clase Setosa desaparece por completo de la representación de la red. En comparación con otras técnicas de minería de datos convencionales, observamos que el Mapa Autoorganizado de Kohonen (SOM) puede separar la clase Setosa y algunas de Virginia clase. Sin embargo, los grupos pueden incluir tanto a Virginia y clases Versicolor. Los dos parámetros principales, el aprendizaje tasa y función de vecindario, se modifican para ayudar a difundir estos grupos se agrupan, pero hacen poco para proporcionar separación de los grupos de Virginia y Versicolor.

En, se aplica el método de agrupamiento de distancia mínima también para los datos de Fisher's Iris. Hay dos grupos principales generado por esta técnica, uno de los cuales describe el Setosa clase, y el otro es para Versicolor y Virginia. Estas dos clases finalmente se dividen después de una serie de reducciones. La referencia analiza un nuevo enfoque para genes Agrupación de datos de expresión basada en aiNet. Es bien sabido que los desafiantes problemas en bioinformática son generalmente caracterizado por conjuntos muy grandes de datos multivariados, que presentan altos niveles de redundancia y patrones ruidosos. Referencia presenta un algoritmo de aprendizaje adaptativo no supervisado para generar el AIS. El algoritmo introduce el culminación de una serie de intentos de

obtener una autoorganización red inmune artificial metaestable. La referencia propone que el aiNet, un algoritmo AIS que explota el biológicamente- características inspiradas del sistema inmunológico, funciona bien en tareas de agrupamiento elementales. Basado en la red inmunológica y principios de maduración de la afinidad, la aiNet realiza un proceso evolutivo en los datos brutos, que elimina los datos redundancia y recupera buenos resultados de agrupamiento.

En resumen, debido a las características intrínsecas del AIS, tales como la adaptación no lineal y la robustez al ruido, los métodos basados en el AIS pueden identificar no solo los patrones en los datos de entrenamiento, pero también los más sólidos. Esta proporciona una buena oportunidad para explorar el AIS como poderosas técnicas de aprendizaje automático. Sin embargo, es difícil obtener una comprensión clara de la relación entre elementos individuales en los datos de entrenamiento e información extraída de la AINE.

En, el AIS es investigado por reglas de asociación minera. para la Clasificación Asociativa (AC). El aire acondicionado toma el ventaja de la minería de reglas de asociación en la extracción de reglas de alta calidad que pueden generalizar con precisión los datos de entrenamiento conjunto. El AIS-AC propuesto evita buscar con avaricia para todas las posibles reglas de asociación, y es capaz de encontrar un conjunto efectivo de reglas asociativas para la clasificación.

Tratamos el proceso de minería de reglas como un problema de optimización de encontrar un conjunto óptimo de reglas de asociación de acuerdo con algunas limitaciones predefinidas. El enfoque AIS-AC propuesto es eficiente en el tratamiento del problema de la complejidad en espacio de búsqueda de reglas. El AIS-AC se implementa de la siguiente manera: En primer lugar, en cada generación, la restricción de soporte se utiliza para filtrar reglas específicas de la población. A continuación, la confianza los valores de las reglas se despliegan para la selección de afinidad. La población está clonada, mutada y diversificada. Finalmente, las mejores reglas de la población se mueven a la memoria en función de la restricción de confianza. El proceso terminará cuando se satisface la restricción de cobertura o el número de generaciones alcanza un número máximo predefinido de generaciones.

De, podemos observar que el número de reglas utilizado para la clasificación en el AIS-AC es mucho más pequeño que que en el enfoque AC.

Adult es una de las cuatro bases de datos utilizadas en las simulaciones. La muestra que el algoritmo de CA puede obtener el conjunto completo de reglas de asociación, pero el AIS-AC tiene sorprendentemente superó al AC con la mayor parte del umbral valores.

El AIS-AC también se puede utilizar para minar clasificación difusa reglas. Para hacer frente a los atributos continuos, Aquí se emplea lógica difusa. Además, la lógica difusa es un método potente y flexible para manejar la incertidumbre y mejorar la comprensibilidad de la regla. La estrategia en este estudio es diferente de "divide y vencerás" y "separa enfoques y conquistar en los árboles de decisión y las listas, respectivamente. De hecho, aplica un mecanismo de impulso a adaptar la distribución de las instancias de entrenamiento en iteraciones. los AIS puede lidiar con lo previamente clasificado erróneamente o descubierto instancias, y la cooperación entre reglas difusas es implícitamente promovido.

La referencia propone una nueva red inmunitaria artificial con diversidad basada en las ideas tomadas de los vivos sistema inmunológico del cuerpo, cuya dinámica se examina a través de simulaciones por computadora sobre el reconocimiento de patrones alfabéticos. Los patrones de memoria en este sistema se clasifican en tres tipos, como se muestra. El reconocimiento de patrones se realiza usando la red inmunológica artificial con estos patrones de memoria de esos tres tipos. Más precisamente, Tipo 1: en un cierto período de preprocesamiento fijo, el patrón de entrada se convierte en el patrón de memoria. Aquí, el patrón de memoria no se actualiza, y, por tanto, se conserva en el estado actual. Tipo 2: cuando el patrón de entrada ha sido reconocido como un patrón de memoria pertenecientes al tipo 1, el patrón de memoria correspondiente en El tipo 2 se actualiza con el patrón de memoria y el patrón de entrada del Tipo 1 reconocido. Tipo 3: el patrón de memoria de este tipo tiene la similitud entre el patrón de memoria actualizado en Tipo 2 y patrón de memoria original (patrón de memoria en Tipo 1) de $M\%$ o superior. Además, el patrón de memoria reconocido y memorizado como un patrón desconocido también pertenece al Tipo 3. Tenga en cuenta que, en el tipo 3, el patrón de memoria, que no se actualizado para L veces, se eliminará.

La investiga la aplicación de lo anterior. red inmune artificial en el sistema de reconocimiento de patrones para alfabetos. La tasa de reconocimiento correcto, tasa de incorrección. reconocimiento, y la tasa de rechazo se emplean para evaluar el rendimiento de sistema. Además, la propuesta artificial La red inmune se compara con la red inmune binaria. para acceder a su tolerancia y reconocimiento de ruido capacidades, cuando se presentan al

ruido binario. Simulación Los resultados muestran que con la diversidad de la red, puede adquirir mayor inmunidad al ruido que la red inmune binaria para patrones de entrada binaria.

La propone una nueva selección clonal. sistema inmunológico artificial basado en métodos. En la mutación proceso, seleccionamos todos los anticuerpos mutados, que tienen mayores afinidades que la célula de memoria actual, y regeneramos una nueva celda de memoria candidata. Los resultados de la simulación demuestran que el algoritmo propuesto tiene una mutación más efectiva rendimiento que el CLONALG. También se hace una comparación aplicando el problema de reconocimiento de patrones ruidosos entre este método y otros modelos AIS. Los resultados del reconocimiento muestran que este enfoque tiene una mayor inmunidad al ruido y puede reconocer los patrones ruidosos invisibles con mayor eficacia. Figura 8 ilustra las prestaciones de reconocimiento del algoritmo propuesto y modelo AIS con 30 generaciones. Obviamente, es menos sensible al ruido y más eficiente en patrones ruidosos reconocimiento que el modelo AIS.

La optimización es un área de aplicación popular para los redes inmunes. La referencia presenta una versión modificada. del modelo de red inmune artificial especialmente diseñado para hacer frente a problemas de optimización multimodal. Es comparado teóricamente con el algoritmo de selección clonal sobre sus estrategias de evolución. Un nuevo sistema inmunológico artificial El método de optimización, denominado CLONALG, se desarrolla para realizar el reconocimiento de patrones y la optimización de ingeniería. Los autores demuestran empíricamente que CLONALG es capaz de aprender los patrones de entrada seleccionando, reproduciendo, y mutar un conjunto de "células inmunes artificiales".

La mencionada aiNet combinando CLONALG con la teoría de la red inmune artificial ha sido exitosa aplicado en varias aplicaciones de compresión y agrupación de datos incluyendo separables no lineales y problemas de alta dimensión. Las mismas razones que conducen a CLONALG son las motivaciones para la versión de optimización de la aiNet, a saber, opt-aiNet. En primer lugar, agrupación de datos puede considerarse como un problema de optimización, donde cada grupo corresponde al pico de aptitud de un subgrupo de individuos dentro de toda la población. En segundo lugar, la aiNet es una extensión de CLONALG con pasos adicionales que implican la interacción de estimulación / supresión de las células de la red juntos. La ventaja de evaluar el grado de similitud entre las células es que es posible mantener un control dinámico del número de células de la red, lo que permite el último hallazgo de soluciones más parsimoniosas.

Opt-aiNet se ha implementado para optimizar varios uniand funciones bidimensionales para evaluar su rendimiento de optimización. Los resultados también se comparan con los obtenidos por CLONALG. En, tres funciones no lineales son explorado: multi, roots y Schaffer's. La ilustra el actuaciones tanto de CLONALG como de opt-aiNet, cuando empleado para la misma optimización de función multimodal problema. Aparentemente, opt-aiNet localiza 61 picos, mientras que CLONALG localiza solo 18. Además, el opt-aiNet posiciona a un solo individuo en cada pico, que puede superar la deficiencia dañina del "desperdicio de recursos" del CLONALG.

Un nuevo modelo de almacenamiento de datos basado en el sistema inmunológico artificial, llamado AIS-DS, se propone para abordar el problema de recursos compartidos en una red de área de almacenamiento (SAN). Especialmente, para las tareas de múltiples usuarios, esta tecnología tiene algunas características esenciales para garantizar la seguridad y la privacidad de información y / o datos. Un examen extenso del El sistema inmunológico artificial de detección de spam se da. los el sistema puede distinguir entre un correo electrónico legítimo (no spam) y no propio de spam.

La agrupación es un proceso de descubrimiento de conocimiento no supervisado que agrupa un conjunto de datos de manera que la similitud intra-clúster es maximizada mientras que se minimiza la similitud entre grupos. Aquí discutimos un novedoso algoritmo de agrupamiento llamado Fuzzy Artificial Agrupación del sistema inmunológico (FAISC), que es basado en la red inmunológica artificial y el sistema difuso. Más precisamente, en el primer comienzo del entrenamiento, inicializamos la red AIS con varios elementos de datos y asignar uno fijo valor. Agregamos un parámetro CHANGE al sistema original, y el patrón del ARB se puede calcular de la siguiente manera.

Para evaluar un solo clúster, usamos tres mediciones, es decir, pureza, equilibrio y f1. Comparamos el FAISC con el método K-means sobre los datos de iris conocidos establecido, y observamos que si el valor de la NAT se fija para ser 1.2 o 1.0, el resultado del FAISC es obviamente mejor que eso del enfoque de k-medias. Especialmente, cuando el NAT es 1.2, el resultado correspondiente es el mejor.

4.Conclusión

En nuestro artículo, proponemos un esquema basado en AIS para clasificación de la calidad del software. También comparamos este método con otras técnicas de clasificación conocidas: Naive Bays, Vecino más cercano y OneR. Los resultados de la simulación demuestran que nuestro AIR es un método prometedor para la calidad del software clasificación.

El éxito de un practicante de AIS se debe mucho a la teoría presentado por los inmunólogos. Se desprende de muchos ejemplos del AIS que la forma en que están diseñados ha cambiado desde los primeros días de la investigación AIS. El original AIS, como los propuestos por Bersini, Forrest y Hightower, se desarrollan utilizando un enfoque interdisciplinario enfoque con clara inspiración en la biología. Más recientemente, sin embargo, el enfoque de diseño del AIS se ha vuelto más orientado a la ingeniería, con menos énfasis en comprender y extraer los modelos biológicos clave.

En este artículo, ofrecemos una descripción general de las propuestas redes inmunes artificiales. Las estructuras y algoritmos de aprendizaje de algunas redes inmunes artificiales típicas son discutido. También demostramos cómo se pueden emplear en lidiar con problemas del mundo real de minería de datos, patrón reconocimiento, clasificación asociativa y función multimodal mejoramiento. Aunque han logrado grandes éxitos en diversas áreas de la ingeniería, todavía hay algunos cuestiones teóricas que necesitan ser exploradas más a fondo, por ejemplo, convergencia y estabilidad al correr. Los desarrollos de la Las redes inmunes artificiales se beneficiarían no solo de la inspiración de principios inmunes naturales, pero también fusionando con otros paradigmas de informática blanda, como las redes neuronales, lógica difusa y algoritmos genéticos. Además, podrían ser generalizado a áreas de aplicación más desafiantes.

Referencias

- [1] Guo, J., Yang, H. "An anti-jamming artificial immune approach for energy leakage diagnosis in parallel-machine job shops", (2018) *Computers in Industry*, 101, pp. 13-24.
- [2] Zhang, W., Zhang, M., Zhang, W., Meng, Y., Wu, H. "Innate-adaptive response and memory based artificial immune system for dynamic optimization", (2018) *International Journal of Performability Engineering*, 14 (9), pp. 2048-2055.
- [3] Saad, S.Z., Saleh, M.H. "Seismic attributes selection and porosity prediction using modified artificial immune network algorithm", (2018) *Journal of Engineering Science and Technology*, 13 (3), pp. 755-765.
- [4] Boufenar, C., Batouche, M., Schoenauer, M. "An artificial immune system for offline isolated handwritten arabic character recognition", (2018) *Evolving Systems*, 9 (1), pp. 25-41.
- [5] Corus, D., Oliveto, P.S., Yazdani, D. "Artificial immune systems can find arbitrarily good approximations for the NP-hard number partitioning problem", (2019) *Artificial Intelligence*, 274, pp. 180-196.
- [6] Rocha, A.D., Lima-Monteiro, P., Parreira-Rocha, M., Barata, J. "Artificial immune systems based multi-agent architecture to perform distributed diagnosis", (2019) *Journal of Intelligent Manufacturing*, 30 (4), pp. 2025-2037.
- [7] Cho, S., Shrestha, B., Jang, W., Seo, C. "Trajectory tracking optimization of mobile robot using artificial immune system", (2019) *Multimedia Tools and Applications*, 78 (3), pp. 3203-3220.
- [8] Nemmour, H., Chibani, Y. "Artificial immune algorithm for handwritten Arabic word recognition", (2017) *International Arab Journal of Information Technology*, 14 (2), pp. 186-194.
- [9] Al-Sinbol, G., Perhinschi, M.G. "Development of an artificial immune system for power plant abnormal condition detection, identification, and evaluation", (2017) *International Review of Automatic Control*, 10 (3), pp. 218-228.
- [10] Wang, M., Feng, S., He, C., Li, Z., Xue, Y. "An Artificial Immune System Algorithm with Social Learning and Its Application in Industrial PID Controller Design", (2017) *Mathematical Problems in Engineering*, 2017, art. no. 3959474.
- [11] Poteralski, A. "Hybrid artificial immune strategy in identification and optimization of mechanical systems", (2017) *Journal of Computational Science*, 23, pp. 216-225.
- [12] Liu, X., Chung, T.-P. "An outsourcing-scheduling problem in a two-stage supply chain via improved immunoglobulin-based artificial immune system", (2017) *Computers and Industrial Engineering*, 113, pp. 819-830.
- [13] Mansor, M.A., Kasihmuddin, M.S.M., Sathasivam, S. "Artificial immune system paradigm in the hopfield network for 3-satisfiability problem", (2017) *Pertanika Journal of Science and Technology*, 25 (4), pp. 1173-1188.
- [14] Sertkaya, C., Yurtay, N. "Artificial immune system based wastewater parameter estimation", (2018) *Turkish Journal of Electrical Engineering and Computer Sciences*, 26 (6), pp. 3356-3366.

- [15] Merabti, H., Farou, B., Seridi, H. "A segmentation-recognition approach with a fuzzy-artificial immune system for unconstrained handwritten connected digits", (2018) *Informatica (Slovenia)*, 42 (1), pp. 96-106.
- [16] Jamali, S., Fotohi, R. "DAWA: Defending against wormhole attack in MANETs by using fuzzy logic and artificial immune system", (2017) *Journal of Supercomputing*, 73 (12), pp. 5173-5196.
- [17] Lanaridis, A., Siolas, G., Stafylopatis, A. "Artificial immune classifier based on ELLipsoidal Regions (AICELL)", (2017) *Computation*, 5 (2), art. no. 31.