

**INTELLIGENT CLASSIFIERS TO DETERMINE THE POWER QUALITY
AFFECTATION****CLASIFICADORES INTELIGENTES PARA DETERMINAR LA AFECTACIÓN
A LA CALIDAD DE LA ENERGÍA ELÉCTRICA****MSc. Víctor Manuel Garrido Arévalo, MSc. Jorge Luis Díaz Rodríguez
PhD. Aldo Pardo García****Universidad de Pamplona**, Facultad de Ingenierías y Arquitectura.
Ciudad Universitaria, Pamplona, Norte de Santander, Colombia.
Tel.: (+577) - 568 5303 Ext. 164.

E-mail: vimaga86@gmail.com, jdiazcu@gmail.com, apardo13@hotmail.com

Abstract: This paper presents a mathematical model and simulation some electric power issues that affects power quality, applying the Discrete Wavelet Transform to obtain the energy distribution of the first 10th detail coefficients in order to process the data and obtain characteristic patterns from each signal. These signals patterns are used to train several intelligent classifiers to determine which has best results regarding the prediction of the class to which it belongs (the energy quality phenomena). On the other hand, with the energy distributions of the detail coefficients establishing a general index of electric power quality and compared with existing indexes.

Keywords: Power quality, harmonics, sag, swell, flicker, wavelet, ANN, SVM.

Resumen: En el presente trabajo se presenta el modelado matemático y la simulación de algunos de los fenómenos que afectan la calidad de la energía, para posteriormente aplicárseles la Transformada Discreta de Wavelet y así obtener la distribución de energía de los 10 primeros coeficientes de detalle de tal forma que al hacer un procesamiento de estos datos se obtengan patrones característicos de cada señal. Con estos patrones entrenan varios clasificadores inteligentes y poder determinar cuál de estos presenta mejor resultados en cuanto a la predicción de la clase a la que pertenece cada uno de los patrones mencionados. Por otra parte, teniendo calculadas las distribuciones de energía de los coeficientes de detalle se procede a la formulación de un indicador general de calidad de la energía y compararlo con los índices existentes.

Palabras clave: Calidad de la energía, armónicos, sags, swell, wavelet, RNA, SVM.

1. INTRODUCCIÓN

Existen fenómenos que afectan la calidad de la energía, y que son muy perjudiciales para los equipos electrónicos, incluso para todos los dispositivos que funcionan a base de energía eléctrica. La identificación de estos fenómenos se hace indispensable para mejorar la calidad de la energía en ocasiones

En el presente artículo se obtiene el modelo matemático para algunos de los fenómenos que afectan la calidad de la energía (THD_v, THD_i, *sag*, *flicker*, *swell*), a los que se les hará un procesamiento mediante la Transformada *Wavelet* para obtener patrones característicos con el fin de que estos sean la entrada a diferentes clasificadores inteligentes y así determinar a cual clase pertenecen.

2. ESTADO DEL ARTE

En los estudios presentados en (Venkatesh *et al.*, 2008), (Elango *et al.*, 2010) (Wijayakulasooriya *et al.*, 2002) (Machado, 2012), (Vega, 2006), (Ajith y Baikunth, 2004), (Resende, 2001), (Tovar, 2009), (García, 2008), (Santafé, 2012) se muestra que el uso de clasificadores inteligentes ha sido común materia de estudio en las aplicaciones de calidad de la energía, especialmente las redes neuronales; así mismo se han limitado a estudiar dichos fenómenos por medio de los índices de medición establecidos, siendo estos particulares a cada uno de los fenómenos y sin ninguna relación entre ellos. Por lo anterior, el presente trabajo se justifica en la medida que se realizará la comparación de distintos clasificadores inteligentes con el fin de determinar cuál presenta mejor respuesta en la identificación de los fenómenos que afectan la calidad de la energía; así mismo se propondrá un Indicador General con el cual se pueda dar una medida de distorsión de la señal ante cualquier fenómeno que la afecte y de esta forma comparar cuál de dichos fenómenos presenta mayor o menor severidad.

3. CALIDAD DE LA ENERGÍA

El estudio de la calidad de la energía eléctrica es el primer y más importante paso para identificar y solucionar problemas del sistema de potencia. Los problemas eléctricos pueden dañar el comportamiento del equipo y reducir su confiabilidad, disminuir la productividad y rentabilidad, e incluso, puede poner en peligro la seguridad del personal (Saucedo y Taxis, 2008).

3.1 Armónicos

Los armónicos son tensiones o corrientes sinusoidales cuya frecuencia es un múltiplo entero de aquella a la cual está diseñado el sistema (frecuencia fundamental, comúnmente 50 o 60 Hz) (Collombet, 2001). Una señal con armónicos se puede representar mediante (Díaz *et al.*, 2012):

$$y(t) = Y_0 + \sum_{n=1}^{\infty} Y_n \sqrt{2} \sin(n\omega t - j_n) \quad (1)$$

Dónde:

Y_0 : Es la amplitud de la componente continua, la cual generalmente es cero en régimen estable.

Y_n : Es el valor eficaz de la componente de rango n .

j_n : Es el desfase de la componente armónica.

3.2 Sag y Swell

Los *sags* y los *swells* son fenómenos similares, el primero corresponde a una disminución de la

amplitud de la señal entre 0.1 y 0.9 en pu, mientras que el segundo a un aumento entre 1.1 y 1.8 en pu.

3.3 Flicker

El *Flicker* o Parpadeo es la “*impresión subjetiva de la fluctuación luminosa*”. El hecho de ser un efecto subjetivo implica que depende de un fenómeno fisiológico ya que es relativo a cada observador y de cómo se ve afectado por dicho fenómeno (Echavarría, 2002). Una señal con *flicker* puede ser

$$v(t) = A[1 + Mu_{\Omega}(t)] \cos(\omega_0 t) \quad (2)$$

Dónde:

A: Es el valor pico de la tensión de red antes de que aparezca la fluctuación.

M es la amplitud de la señal moduladora.

ω_0 : Es la frecuencia de la tensión de red.

$u_{\Omega}(t)$: Representa la señal de frecuencia Ω que modula la tensión de red y cuya amplitud es M, la cual varía entre 0 y 1. Por lo general es una onda cuadrada.

4. CLASIFICADORES INTELIGENTES

A continuación se describen los clasificadores utilizados en el presente trabajo.

4.1 Redes Neuronales

Las redes neuronales artificiales son estructuras paralelas inspiradas en las neuronas biológicas. Una red neuronal está compuesta por multitud de elementos simples, neuronas, interconectadas de una forma más o menos densa y cuyo funcionamiento en conjunto puede dar lugar a un procesamiento no lineal complejo. Las redes son capaces de ajustar su comportamiento a partir de datos experimentales y en base a alguna figura de mérito de modo que son muy útiles en problemas donde el conocimiento del problema es incompleto o varía en el tiempo (Pajares, 2011), (Martínez *et al.*, 2012)

En el presente estudio se usarán las siguientes redes neuronales:

- Perceptrón multicapa – Red 1
- Red de base radial – Red 2
- Red de Propagación en Cascada – Red 3

4.2 Support Vector Machine

Los *Support Vectors Machine (SVM)* son un conjunto de algoritmos de aprendizaje basados en la teoría del aprendizaje estadístico. Esta técnica fue inicialmente un clasificador lineal biclase para datos separables y permite encontrar un modelo

lineal que separe los elementos de ambas clases; posteriormente esta técnica fue adaptada a problemas de clasificación con datos no separables e incluso para resolver problemas de regresión (Pajares, 2011), (Jiménez, 2010), (Santafé *et al.*, 2013).

Para el presente trabajo se utilizarán las configuraciones, biclase manual (SVM1), *Minimum Output Coding (code_MOC)* (SVM2), *Error Correcting Output Coding (code_ECOC)*, (SVM3) y Clasificación *One vs. All.* (SVM4)

5. SIMULACIONES

El desarrollo de las simulaciones parte de la obtención de las señales de cada uno de los fenómenos a analizar, así pues, en las figuras 1, 2, 3 y 4 se pueden apreciar un ejemplo de cada una de las señales utilizadas en este estudio.




Fig. 1. Señales con Armónicos

Para la simulación de los armónicos se tendrá en cuenta la norma IEC 61000-3-6 para fijar los límites de cada componente. En la Figura 1 se presenta un ejemplo de señal con presencia de armónicos.

En cuanto la simulación de los fenómenos *swell* y *sags*, se establece en el código de generación, la duración de los mismos de forma aleatoria, así mismo se establecen los rangos de variación de la magnitud en por unidad de acuerdo a lo indicado anteriormente. De esta forma se presentan en la Figura 2 y la Figura 3 señales con *sags* y *swell* respectivamente.




Fig. 2. Señales con Sags




Fig. 3. Señales con Swell

Las simulaciones de señales con *flicker* se realizan teniendo en cuenta que dichas señales se describen con la Ecuación 2, así:

$$A = 1 \text{ p.u.}$$

$$w_0 = 60 \text{ Hz.}$$

$u_\Omega(t)$: Se usan dos señales moduladoras, una sinusoidal y una onda cuadrada.

M : Valor variable entre 0 y 1.0




Fig. 4. Señales con Flicker

Posteriormente, se aplica la Transformada *Wavelet* a cada una de las señales con el fin de obtener los coeficientes de detalle. Utilizando la técnica descrita en (Navarrete y Andrade, 2006) que se muestra en la Ec. 3:

$$dp(j)\% = \left[\frac{en_{dist(j)} - en_{ref(j)}}{en_{ref(7)}} \right] \cdot 100\% \quad (3)$$

Se obtiene la distribución de energía de cada uno de los niveles de descomposición de la señal y de esta forma se logran tener patrones característicos para cada una de las clases de señales.

Así pues en la figura 5 se puede apreciar los patrones de la distribución de energía para las señales con armónicos, es fácilmente identificable esta señal puesto que presenta dos picos, uno positivo en el coeficiente de detalle 5 y otro pico negativo en el coeficiente 7.




Fig. 5. Patrones característicos - Armónicos

En la Figura 6 se muestra los patrones de la distribución de energía para las señales con *swell*, se puede apreciar que esta señal sólo tiene un pico positivo en el coeficiente de detalle 7, pudiéndose presentar en algunas muestras dicho pico en el nivel 6.




Fig. 6. Patrones característicos - Swells

Para el caso de los sags, los patrones característicos se muestran en la Figura 7, para estos se aprecia que el pico en el coeficiente de detalle 7 en este caso es negativo y tiene relación con la señal de origen, porque mientras en swell, que es una elevación del nivel de tensión el pico es positivo y en el sag, que es una disminución del nivel de tensión el pico es negativo.

En la figura 8 se pueden apreciar los patrones característicos de la señal con flicker, estos patrones son los más complejos de los anteriores puesto que presentan dos picos positivos en los coeficientes de detalle 6 y 8 y un pico negativo más marcado en el coeficiente 7.




Fig. 7 Patrones característicos - Sags




Fig. 8. Patrones característicos - Flicker

6. RESULTADOS

Los patrones obtenidos mediante la ec. 3 son los datos de entrada a los clasificadores seleccionados, así pues para el entrenamiento de estos se usan 500 muestras por clase, para la validación se usan 200 y para la prueba se usan 1000 muestras por clase.

6.1 Redes neuronales

Perceptrón multicapa: Para este caso la red neuronal tendrá tres capas las cuales tendrá 10, 4 y 1 neurona en cada capa.




Fig. 9. Resultados MLP - Entrenamiento




Fig. 10. Resultados MLP - Validación




Fig. 11. Resultados MLP - Prueba

6.2 Support Vector Machine

En la figura 12 se presenta la comparación entre los elementos esperados y los predichos para el caso de entrenamiento, así mismo en la figura 13 y la figura 14 se muestran los resultados para las simulaciones de validación y prueba de los datos.




Fig. 12. Resultados SVM 1 - Entrenamiento




Fig. 13. Resultados SVM 1 – Validación




Fig. 14. Resultados SVM 1 – Prueba

6.3 Comparación de errores

En la Tabla 1 se puede apreciar que la Red 1, en este caso la perceptrón multicapa, que siendo la red más sencilla, es la que mejores resultados presenta en la identificación de las clases. Siendo el caso contrario el de la red de base radial, la cual presenta errores del 100% en la validación y en la prueba, que como bien se mencionó anteriormente obedece posiblemente a un sobreentrenamiento. Por otra parte en el caso de los SVM, la configuración que mejores resultados presenta es la que usa el algoritmo *Minimum Output Coding* para decodificar la salida y convertirla en las clases requeridas.

Tabla 1: Porcentaje de errores por clase

Clasificador	Armónicos	Swell	Sags	Flicker
RED 1 Newff	0,4	1,9	1,1	3,3
RED 2 Newrb	98,7	50,9	62,7	66,2
RED 3 Newcf	1,8	1,8	0,8	2,0
SVM 1	4,5	3,5	5,2	5,8
SVM 2 OneVsAll	4,7	0,5	4,6	14,3
SVM 3 ECOC	5,7	0,4	2,5	14,4
SVM 4 MOC	3,8	0,3	2,3	11,1

En la Tabla 2 se muestran los errores totales de los clasificadores, como consecuencia de la Tabla 1 es predecible que la red neuronal tipo perceptrón multicapa es la que presenta mejores resultados a nivel global, incluso por encima de cualquier SVM de los que se utilizaron para este trabajo.

Tabla 2: Porcentaje de Errores Totales

Clasificador	Ent/mnto	Validación	Prueba	Total
RED 1 Newff	0,5	1,87	2,2	1,52
RED 2 Newrb	0,15	100	84,02	61,39
RED 3 Newcf	0,8	2	1,97	1,59
SVM 1	4,72	4,72	4,72	4,72
SVM 2 OneVsAll	5,6	6,25	6,22	6,02
SVM 3 ECOC	4,95	6	5,5	5,48
SVM 4 MOC	4	4,37	4,8	4,39

6.4 Indicador general de Calidad de la Energía

Tal como se menciona en (Suárez, 2005) y en (Calvas, 2001), existen numerosos indicadores para medir cada uno de los diferentes fenómenos que afectan la calidad de la energía, los cuales no tienen relación entre sí, puesto que por ejemplo, dada una señal que presente armónicos a la cual se le calcule el THD y otra señal que presente un *swell* y a este se le determine usando la variación de la amplitud o su duración, no hay forma, con sólo dichos valores, de interpretar si es la primera o la segunda señal la que presenta mayor afectación.

Todo este proceso debe arrojar un número que mida cuán cercano o lejos está la señal de estudio en referencia a la señal sinusoidal pura, para la cual el indicador marcará 0.0, y se convierte este en la referencia, así pues entre más grande sea el indicador general propuesto, será evidencia de que la señal en cuestión está distante de ser sinusoidal.

Así pues mediante la Ec. 4 se define el indicador.

$$Ind = \frac{\sum_{i=1}^n |E_{coef_i}|}{n} \quad (4)$$

Donde:

E_{coef_i} : Es la energía del coeficiente de detalle i .

De esta forma, se obtienen los siguientes resultados para 10 señales de prueba.

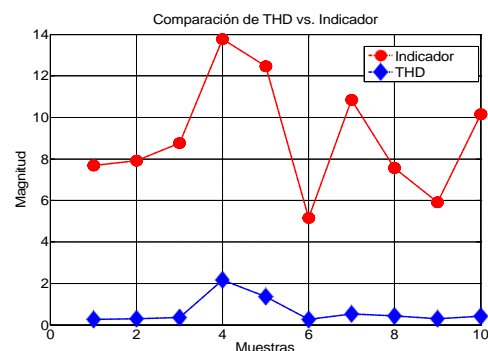


Fig. 15. Parámetros de Armónicos vs. Indicador

De acuerdo a la Figura 15 se puede deducir que es la señal 6 la que presenta un indicador más bajo, por tanto será la que estará más cerca de la sinusoidal pura y por el contrario será la señal 4 la que presentará una mayor distorsión. Tal como se muestra en la Figura 16




Fig. 16. Señales de mayor y menor distorsión – Armónicos

En la figura 17 se aprecia que la señal 1 muestra el menor indicador de distorsión, mientras que, la señal 7 corresponde a la que presenta mayor distorsión, las diferencias entre dichas señales se puede apreciar con mayor detalle en la figura 18, en esta, se puede observar que si bien la señal 1 no es la que presenta menor variación de la amplitud ni tampoco menor duración, si es la que presenta menor indicador, esto se da porque esta señal no presenta transitorios en los cambios, sino que es un cambio suave, contrario sucede en la señal 7, en donde se puede apreciar que hay un salto brusco al aparecer el *swell*. Dichos cambios bruscos producen un incremento en la energía de los coeficientes y por tanto un incremento también en el indicador general.




Fig. 17. Parámetros de Swell vs. Indicador




Fig. 18. Señales de mayor y menor distorsión – Swell

De la misma forma en la Figura 19 se muestra que la relación existente entre los parámetros de medición de *sags* y el indicador general propuesto es aproximada a una relación lineal. Así mismo se puede observar que es la señal 5 la que presenta mayor grado de distorsión, mientras que es la señal 9 la que presenta un menor indicador. En la Figura 20 se pueden observar con mayor detalle las señales de mayor y menor distorsión.




Fig. 19. Parámetros de Sag vs. Indicador

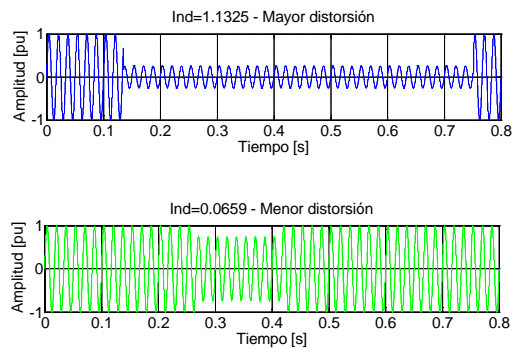


Fig. 20. Señales de mayor y menor distorsión – Sag

En la Figura 21 se muestra la comparación entre los indicadores para 100 señales con *sags* y 100 señales con *swell*, puede apreciarse que los datos están centrados en el rango 0.2 y 0.4, aunque con una pequeña desviación, llegando el máximo indicador a un valor cercano a 2.0.




Fig. 21. Comparación Indicador - swell y sag

En la figura 22 se presentan la comparación entre los indicadores de armónicos y flicker, dándose estos valores en un rango mayor al de los sags y swell, ya que los primeros tienen valores comprendidos entre 0 y 18, siendo evidente de todas formas que son los armónicos los que presentan mayor indicador de distorsión, es decir, en comparación con las otras 3 señales, son las muestras de armónicos las que están más distantes de la señal sinusoidal pura y por el contrario, son los swell los que presentan menor indicador de forma general.




Fig. 22. Comparación Indicador - Swell y Sag

7. CONCLUSIONES

En el trabajo se utilizan los 10 primeros coeficientes de detalle de la Transformada Wavelet ya que estos permiten obtener patrones diferenciados para cada una de las señales. Así mismo, la distribución de la energía de cada uno de los coeficientes permite diferenciar aún más los patrones, ya que de lo contrario todos tendrían la misma forma, con un pico en el coeficiente de detalle 7, en el que se presenta la mayor cantidad de energía.

Se realizó un estudio detallado de las diferentes técnicas inteligentes de clasificación, de estas se seleccionaron dos grandes bloques, redes neuronales y *Support Vector Machine*.

En el grupo de las redes neuronales, el mejor clasificador resultó ser el perceptrón multicapa, la red más simple de las analizadas, en las tres etapas, entrenamiento, validación y prueba. Para el caso de los *Support Vectors Machine*, el que mejor resultados presenta es la configuración *Minimum Output Coding*.

De forma global, con la investigación realizada en el trabajo se logró identificar que el mejor clasificador es sin lugar a dudas el perceptrón multicapa ya que presenta un porcentaje de error total de 1.52%, seguido muy de cerca por la red de propagación en cascada con un error de 1.59%.

Así mismo y como principal elemento diferenciador de este trabajo, se estableció un Indicador General de Calidad de la Energía que permite comparar todos los fenómenos que perturban la señal, en donde el valor ideal es cero, que es el que corresponden a la onda sinusoidal, este indicador guarda proporción con los índices de medición clásicos de cada uno de las perturbaciones, siendo de mayor magnitud para los fenómenos de armónicos y flicker, ya que son estas, las señales que presentan mayor distorsión respecto a la onda sinusoidal pura; por el contrario son los sags y los swell los que presentan más bajo índice.

RECONOCIMIENTO

Este trabajo se desarrolló con la colaboración de la Universidad de Pamplona a través de la Maestría en Controles Industriales y el Grupo de Investigación en Sistemas Energéticos, el MSc. Jorge Luis Díaz Rodríguez y el PhD. Aldo Pardo García.

REFERENCIAS

- Ajith, A. and Baikunth, N. (2004). "Artificial neural networks for intelligent real time power quality monitoring system". Vol. 56, No. 6.
- Calvas, R. (2001). *Cuaderno Técnico No. 141: Las perturbaciones eléctricas en BT*. Schneider Electric, enero.
- Collombet, C. et al. (2001). *Cuaderno Técnico No. 152: Los armónicos en las redes perturbadas y su tratamiento*. Schneider Electric, enero.

- Díaz R., J. L.; Pabón, L. D. y Torres, I. (2012). Análisis comparativo de la distorsión armónica en inversores de potencia. *Revista Colombiana de Tecnologías de Avanzada*, Vol. 1, No. 19.
- Echavarría, R. (2002). Síntesis de un regulador monofásico de tomas de CA para aplicaciones de media y baja tensión. Tesis Doctoral. Centro Nacional de Investigación y Desarrollo Tecnológico, México.
- Elango, M. K., *et al.* (2010). "Application of Neural Networks for Power Quality Disturbance Classification Using Hilbert Huang Transform". *European Journal of Scientific Research*, Vol. 47, No. 3, pp. 442-454.
- García, E. (2008). *Valoración de la Calidad de la Energía Eléctrica Respecto a Huecos de Tensión: Índices y Niveles de Calidad*. Tesis Doctoral. Universidad Politécnica de Valencia. España.
- Jiménez, L. (2010). "Al Interior de una máquina de soporte vectorial". *Revista de Ciencias*, Universidad del Valle, Cali, Octubre.
- Machado, R. N. M., Bezerra, U. H., Tostes, S. C. F., Freire, M. E. L and Meneses, L. A. (2012). Application of Wavelet Transform and Artificial Neural Network to Extract Power Quality Information from Voltage Oscillographic Signals in Electric Power Systems, *Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology*, Ed. InTech.
- Martínez, C., Díaz R., J. L. y Pardo G., A (2012). Aplicación de redes neuronales al control de velocidad en motores de corriente alterna. *Revista Colombiana de Tecnologías de Avanzada*. Vol. 2, No. 20.
- Navarrete M., M. y Andrade M., S. (2006). "Análisis y Tratamiento de la Señal Electrocardiográfica Para la Detección de Parámetros de Normalidad Bajo la Plataforma Labview "Adpan-Ecg" Universidad Pontificia Bolivariana, Bucaramanga, julio.
- Pajares, G. (2011). *Aprendizaje Automático*. Ediciones de la U., Colombia.
- Resende, J. W. (2001). "Identification of power quality disturbances using the MATLAB® Wavelet Transform Toolbox". Presentado en International Conference on Power Systems Transients (IPST), Rio de Janeiro, Brasil, Junio pp. 24-28.
- Santafé, P.; Díaz R., J. L. y Gualdron, O. (2013). LSSVM aplicada en la estimación de la resistencia de rotor en motor de inducción jaula de ardilla. *Revista Colombiana de Tecnologías de Avanzada*, Vol. 1, No. 21.
- Saucedo D. y Taxis, J. (2008). *Factores que afectan la calidad de la energía y su solución*. Tesis de Maestría. Escuela Superior de Ingeniería Mecánica y Eléctrica. México, D.F.
- Suárez, J. A. (2005). "Análisis de la distorsión armónica y los efectos de atenuación y diversidad en áreas residenciales". *IEEE Latin America Transactions*, Vol. 3, No. 5, Dic.
- Tovar, D. A. (2009). "Wavelet transform and support vector machines for the arrhythmia identification". *Revista de Investigación Universidad del Quindío*, Vol. 19, No. 10. Colombia.
- Vega, V. *et al.* (2006). "Detección e identificación de eventos de la calidad de la Energía eléctrica utilizando la transformada *Wavelet* discreta y redes neuronales". *Revista UIS Ingenierías*.
- Venkatesh, C. *et al.* (2008). "Wavelet based modular neural network for power quality disturbance classification". Presentado en la XXXII National Systems Conference, NSC, Roorkee, Uttarakhand, India.
- Wijayakulasooriya, J. V. *et al.* (2002). "Electric power quality disturbance classification using self-adapting artificial neural networks", *Generation, Transmission and Distribution, IEE Proceedings*, Vol. 149, No. 1, pp. 98-101, Jan.