

DOS MODELOS PARA LA PREDICCIÓN DE INCENDIOS FORESTALES EN WHITECOURT FOREST, CANADA

C. VEGA GARCIA

P.M. WOODARD

S.J. TITUS

Dpt. of Forest Science, 751 General Services Building,
University of Alberta, Edmonton, Alberta, Canada T6G 2H1

W. L. ADAMOWICZ

Dpt. of Rural Economy, 515 General Services Building,
University of Alberta, Edmonton, Alberta, Canada T6G 2H1

B. S. LEE

Canadian Forest Service, Northern Forestry Centre, 530-122 Street, Edmonton, Alberta, Canada T6H 3S5

RESUMEN

El área forestal de Whitecourt, Alberta, Canadá, ha servido como zona piloto para el desarrollo de dos modelos de predicción diaria de incendios forestales causados por agentes de ignición humanos: uno es un modelo de regresión logarítmica (el modelo *logit*) y el otro un modelo de red neuronal artificial. Ambos modelos alcanzaron una precisión similar en sus predicciones (74 vs. 76%). Este artículo describe la metodología seguida para el desarrollo de los modelos, presenta los resultados alcanzados y discute las implicaciones de su posible aplicación práctica en la planificación de la extinción.

PALABRAS CLAVE: Predicción
Incendios forestales
Agentes humanos
Modelos
Canadá

INTRODUCCION

Los incendios forestales de causalidad humana no son sucesos aleatorios. A menudo se localizan cerca de núcleos habitados y tienden a seguir patrones estacionales, semanales, e incluso diarios (Martell *et al.*, 1987; Todd, Kourtz, 1991). Los técnicos forestales expertos en la lucha contra incendios son capaces generalmente de evaluar futuras tendencias y localizaciones en la ocurrencia de incendios (Cunningham, Martell, 1976; Todd, Kourt, 1991), pero rara vez son capaces de proporcionar predicciones concretas para áreas geográficas específicas.

Recibido: 6-2-97

Aceptado para su publicación: 11-12-98

Un modelo capaz de predecir incendios, día a día, para demarcaciones geográficas de interés en la lucha contra incendios haría la distribución de recursos de extinción más eficiente y reduciría costes, daños y pérdidas. Sin embargo, el desarrollo de un modelo de predicción de incendios siempre presenta una gran dificultad, que es la incertidumbre asociada al comportamiento humano en relación al fuego. Por esta razón, muy probablemente, hay tan pocos operativos en la actualidad (Vega García, 1994).

La probabilidad de incendio determinada por la presencia y actividad de agentes de ignición se denomina *riesgo humano*, de acuerdo a la terminología anglosajona (*human risk*, Merrill, Alexander, 1987). Los datos necesarios para la evaluación del riesgo en un área, como son el número de personas presentes un día determinado, o las actividades a que se dedican, no están generalmente disponibles (Martell *et al.*, 1987). Esto ha llevado a los investigadores a evaluar técnicas para la obtención indirecta de estimaciones del riesgo, línea en la que se enmarca este trabajo. El objetivo de este estudio fue modelizar la ocurrencia diaria de incendios forestales causados por personas utilizando variables temporales y meteorológicas, y variables geográficas, capaces de describir la distribución y variación de niveles de riesgo humano y del peligro general (meteorología + topografía + combustibles) en un área de estudio.

La hipótesis principal de este trabajo es que la extensión y localización de actividades humanas está determinada por las condiciones del medio forestal en cualquier momento.

Esta hipótesis implica que pueden utilizarse ciertas variables geográficas y temporales para estimar indirectamente el riesgo humano en ciertas áreas, para períodos específicos de tiempo. Chou *et al.* (1990) han encontrado que variables geográficas, como el tipo de vegetación y la cercanía a carreteras o a áreas de acampada, estaban relacionadas con la ocurrencia de incendios forestales en el distrito forestal de San Jacinto, California. Aún más, este estudio demostró que estas variables eran adecuadas para la predicción de incendios, aunque no se utilizaron para realizar predicciones diarias. Una extensión de esta hipótesis, propuesta en primer lugar por Phillips, Nickey (1978), es que dadas las mismas condiciones en dos entornos forestales idénticos, los niveles de riesgo deben ser iguales. Se admite que esta simplificación del proceso que conduce a un incendio forestal sólo considera la influencia de estímulos externos en el comportamiento humano, que son fáciles de medir, y deja de lado motivaciones o predisposiciones personales, que son difíciles de evaluar.

AREA DE ESTUDIO

Whitecourt Provincial Forest (53°-55° Norte, 114°-118° Oeste) fue seleccionada como área piloto para el estudio porque se disponía de suficiente información geográfica y meteorológica para este área forestal (Fig. 1). Pertenece a la Provincia de Alberta, en Canadá, y se encuentra al noroeste de la capital, Edmonton. Cubre un área de 21.507 km², de relieve suave y altitud entre 800 y 1300 m. Whitecourt Forest está situada en la zona climática Boreal, y participa de dos de las cinco ecoregiones que componen esta zona climática en Canadá, según Strong, Leggat (1981)¹.

¹ Esta es la referencia principal en este apartado, mientras no se indique lo contrario.



Fig. 1.—Situación de Whitecourt Forest en la provincia de Alberta, Canadá
The location of the Whitecourt Forest in the Province of Alberta, Canada

El noreste del área de estudio pertenece a la ecoregión de Masas Mixtas Boreales (*Boreal Mixedwood*). La precipitación anual es de 440 mm y más del 70 % de la precipitación anual ocurre en el verano. La temperatura media de verano (Mayo a Septiembre) es de 12,0°C. Esta zona está dominada principalmente por bosques de chopo (*Populus tremuloides*, con cantidades secundarias de *Populus balsamea*) sobre Luvisols. Las especies climáticas potenciales en las localizaciones más favorables son *Picea glauca* y *Abies balsamea*.

Hacia el suroeste de Whitecourt Forest encontramos la ecoregión Boreal de pie de ladera (*Boreal Foothills*). Esta ecoregión es la más diversa en especies arbóreas de la Provincia, siendo codominantes *Populus tremuloides*, *Populus balsamea* y *Pinus contorta*, y habituales *Betula papyrifera*, *Picea glauca*, *Picea mariana* y *Abies sp.* Tanto *Picea glauca* como *Picea mariana* son especies climáticas potenciales. Bajo esta vegetación se desarrollan típicamente Luvisols. El régimen de precipitaciones sigue siendo continental, siendo el verano la estación húmeda, con un máximo de precipitación en Julio (370 mm entre Mayo y Septiembre). La precipitación media anual es de 570 mm y la temperatura media de verano es de 11,5°C. El rango de temperaturas no es tan grande como en la ecoregión anterior. Al menos 20 días al año la zona sufre vientos cálidos y secos del oeste,

denominados *chinook*.

Las actividades de mayor importancia económica en Whitecourt Forest son, por orden, las forestales, las de prospección y extracción de petróleo, el pastoreo, y la pesca recreativa.

Las actividades forestales se distribuyen a lo largo de la ecoregión de masas mixtas y son predominantes en todo el área de las Foothills, que incluye algunas de las masas más productivas de Alberta. Hay algunas porciones dedicadas a la agricultura (producción de forraje y pastos, mayormente). Las actividades recreativas se limitan generalmente a localizaciones donde el acceso es posible. Con respecto al acceso, hay que hacer notar que Whitecourt es probablemente más accesible que ningún otra área forestal en la provincia, debido no tanto a la presencia de una autopista y varias carreteras que enlazan los escasos núcleos urbanos (de poca entidad), sino a las oportunidades que crean las exploraciones petrolíferas y las extracciones de madera en todo el área.

El total de los 21.507 km² de Whitecourt Forest han sido inventariados en el último inventario forestal de la provincia, que se concluyó en 1984 (Alberta Energy and Natural Resources, 1985). El 72 % de Whitecourt fue clasificado como forestal en producción, el 24 % como improductivo y el 3 % como potencialmente productivo. El volumen maderable es de 272 millones de m³, compuesto en su mayoría por *Picea glauca* y *Pinus contorta* (68 %). La propiedad pertenece mayoritariamente al gobierno federal, que establece contratos (*Forest Management Agreements*, *Forest Quota Areas*) con empresas del sector forestal para la gestión de los recursos, aunque la propiedad privada ha aumentado en los últimos años.

Incendios forestales en Whitecourt Forest

Como principal conclusión desde el punto de vista del peligro meteorológico de incendios forestales, hay que destacar que las condiciones climáticas condicionan un régimen de ocurrencia con dos picos, uno en primavera antes de las lluvias y el reverdecimiento de la vegetación, y otro hacia el final del verano y principios de otoño. La conjunción de estos períodos de mayores temperaturas y menor humedad con los *chinook* pueden crear situaciones de peligro extremo, según Simard (1973); solamente el 20 % de los días puede considerarse que los incendios requerirán escasa o nula intervención. En otro 40 % sólo se requerirán esfuerzos mínimos para su control. Es probable que ocurran fuegos de superficie poco intensos en el 20 % de los días, y fuegos de intensidad moderada a muy severos en un 17 % de los días. En el 3 % de los casos pueden desarrollarse fuegos de copas, potencialmente incontrolables durante las horas del día. Estas condiciones extremas de peligro suelen ocurrir en períodos breves cada pocos años.

Las estadísticas de incendios disponibles para los años 1986-1990 indican que el 60 % de los incendios que se produjeron, 510 en total, tuvieron causas humanas. Del total, el 15,5 % tuvieron como causa la quema de rastrojos, residuos o pastos, el 15,3 % se debió a industrias no forestales, el 10,8 % a actividades recreativas, el 6,3 % a causas variadas (negligencias, descuidos, cohetes, etc), el 4 % fueron intencionados, el 3,3 % fueron ocasionados por el ferrocarril, y el 2,9 % se debieron a la industria forestal. Sólo un 0,8 % se clasificaron como de causas desconocidas.

Los combustibles más afectados fueron los pastos (29 %), seguidos de la *Picea maria-*

na (17 %). Los incendios se originaron en terreno federal en un 76 % de los casos, y en propiedad particular el 23,3 %. La mayoría de los incendios fueron fuegos de suelo (68 %), aunque también hubo fuegos de subsuelo (25,7 %), y de copas (6,3 %).

La distribución por tamaño final de los 301 incendios de origen humano recoge 140 incendios menores de 0,1 ha (46,5 %), 128 incendios entre 0,1 y 4 ha (42,5 %), 26 entre 4 y 40 ha (8,6 %), seis entre 40 y 200 ha (2,0 %), y uno sólo mayor de 200 ha (0,3 %).

METODOLOGIA

Identificación de variables relevantes al problema de los incendios

El primer objetivo del estudio fue identificar las variables más importantes para la predicción de incendios en Whitecourt Forest, agrupadas en dos tipos: factores *geográficos*, muy variables en el espacio pero poco variables en el tiempo, y factores *temporales*, muy cambiantes en el tiempo durante el período de estudio, pero con poca variabilidad espacial.

El estudio se vio facilitado por estar disponible abundante información geográfica en formato digital, es decir apta para su gestión con un Sistema de Información Geográfica, en este caso ARC/INFO (ESRI Inc., 1991). Al disponerse de software y de abundancia de datos para el estudio, la inclusión de todo tipo de factores geográficos no planteaba problemas de tipo técnico. Sin embargo, como la información relativa a características geográficas cambia en el tiempo debido a la construcción de nuevas carreteras e infraestructuras, por ejemplo, era importante utilizar un período de tiempo corto para el estudio, porque la precisión de la información geográfica disponible sería mayor, pero el período debía ser suficientemente largo para recoger tendencias en los patrones de inicios humanos de incendios. En consecuencia seleccionamos para el desarrollo del modelo el período de cinco años entre 1986 y 1990, ya que los datos disponibles sobre incendios en este intervalo se podían considerar completos y suficientes para mostrar patrones en el inicio de incendios causados por personas. La información geográfica había sido también digitalizada en este período (1986-1987). De esta manera, estimamos que serían minimizados los errores que se cometen al relacionar incendios con características geográficas inexistentes cuando éstos se produjeron.

Se llevó a cabo un análisis de numerosos factores geográficos y temporales en su relación con la ocurrencia de incendios mediante el test χ^2 , descrito en Vega García *et al.* (1993). Este estudio previo proporcionó como resultado que las variables temporales que se listan a continuación están relacionadas significativamente con la ocurrencia de incendios en Whitecourt Forest: FFMC, DMC, BUI, ISI, FWI —componentes del índice meteorológico de peligro de incendios canadiense (Van Wagner, 1987) que se describen en un apartado posterior—, humedad relativa, velocidad del viento, y mes del año. Las variables geográficas siguientes: distancia a carreteras, a ciudades, a áreas de acampada, elevación, propiedad, valor comercial de la masa, y tipo de combustible, también están relacionadas significativamente con la ocurrencia de incendios en Whitecourt. Con estas variables se abordó el proceso de construcción del modelo de predicción de ocurrencia de incendios causados por personas más eficazmente.

Selección de los modelos

El modelo logit

En una cierta localización y para un momento dado, hay sólo dos resultados para la compleja interacción entre los agentes de ignición potenciales (las personas) y el entorno físico forestal: o bien ocurre un incendio, o no ocurre. Una variable dependiente binaria como Incendio Sí/No se puede estudiar con diversas técnicas de análisis para datos binarios. El modelo logit ofrece ventajas de cálculo sobre otros como el modelo probit (Maddala, 1983) y además, ya se han utilizado con éxito modelos logit en aplicaciones semejantes (Martell *et al.*, 1987; Loftsgaarden, Andrews, 1992; Chou *et al.*, 1993).

El modelo logit supone la existencia de una variable dependiente "latente", en este caso, la probabilidad diaria de ocurrencia de incendios (al menos uno), que no es observable más que como una variable lógica Y de valor 0 (no ocurrencia de incendios) ó 1 (ocurrencia de incendios ese día) (Maddala, 1988). En este modelo, el logaritmo de la razón de las probabilidades de los dos posibles resultados es una función lineal de las variables independientes (Maddala, 1988),

$$\ln \left(\frac{P_i}{1 - P_i} \right) = \beta_0 + \sum_{j=1}^{j-k} \beta_j x_{ij} \quad [1]$$

donde P_i es la probabilidad de $Y = 1$, para cualquier observación i ,

$1 - P_i$ es la probabilidad de $Y = 0$,

x_{ij} son las variables explicativas

y $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ son los $k+1$ parámetros a estimar.

La estimación del modelo se debe realizar por métodos de máxima probabilidad cuando se analizan observaciones individuales como Incendio Sí/No (Stynes y Peterson, 1984). Para estimar los parámetros del modelo se debe recoger información sobre los incendios y sus características en el área de estudio, pero como los incendios son sucesos raros en Whitecourt, se comprende que los datos necesarios no se obtengan fácilmente. Una muestra aleatoria de observaciones diarias en Whitecourt Forest, para cualquier período, incluye muy pocas observaciones con incendios y un gran número de observaciones sin incendios. Este problema ha sido mencionado a menudo en otros estudios (Martell *et al.*, 1987). El modelo logit permite utilizar diferentes proporciones de muestreo para las dos subpoblaciones de observaciones (con incendios/sin incendios) y obtener una base de datos equilibrada para la estimación del modelo (Maddala, 1988). Pueden realizarse predicciones para el total de la población haciendo a posteriori el ajuste correspondiente en el coeficiente β_0 del modelo (Prentice, 1986; Maddala, 1988, Hosmer y Lemeshow, 1989). Esta transformación fue la razón determinante en la elección del modelo logit para este estudio.

El modelo de red neuronal backpropagation

Las redes neuronales artificiales (ANN) pueden definirse como "una nueva forma de computación, inspirada en modelos biológicos" (Hilera, Martínez, 1995), en concreto, en el sistema de computación que se cree utiliza el cerebro humano (Klimasauskas, 1991a) el cual está constituido fundamentalmente por neuronas. La forma más sencilla y habitual de desarrollar redes es simularlas mediante un software específico en un ordenador convencional.

Las redes están formadas por numerosos elementos procesadores de información (PEs, los equivalentes artificiales de las neuronas biológicas) muy interconectados entre sí, aunque capaces sólo de operaciones relativamente simples (Hilera y Martínez, 1995). Los PEs se estructuran jerárquicamente, generalmente en niveles. Hay típicamente un nivel de entrada que presenta datos a la red, un nivel de salida que proporciona la respuesta de la red a los datos de entrada, y entre ellos uno o más niveles *ocultos*- sin relación con el exterior- que procesan los datos (NeuralWare Inc., 1991). De acuerdo con lo que ocurre en los sistemas biológicos, las conexiones entre PEs de un mismo o distinto nivel pueden variar en fuerza o peso, y en estructura. La organización de los PEs o neuronas de la red en niveles, su número y sus conexiones definen la *arquitectura* de la red. Esta estructura confiere a las ANN una gran capacidad para procesar datos y la habilidad para realizar procesos inteligentes como: (1) aprender a partir de ejemplos, (2) generalizar el conocimiento adquirido a nuevos casos, y (3) reconocer tendencias y patrones en los datos.

Estas capacidades son adquiridas por la red a través de una fase de *aprendizaje*. El aprendizaje es el proceso de modificación de las conexiones —pesos— entre PEs en respuesta a los datos presentados a la red en el nivel de entrada. Este proceso de aprendizaje termina cuando la modificación de los pesos se estabiliza ante el flujo de datos. La modificación de los pesos responde a criterios determinados por la regla de aprendizaje (NeuralWare Inc., 1991). Existen numerosas reglas de aprendizaje que corresponden a los numerosos modelos de red desarrollados hasta la fecha, pero en todos los modelos la información queda almacenada en las conexiones, en forma distribuida. En este proceso no puede decirse que la red ajusta una función a los datos sino que la red es la función, la red se adapta para ajustarse a las características de la base de datos de *entrenamiento* (Klimasauskas, 1991a). El mecanismo de aprendizaje de una red es probablemente su rasgo más importante.

Las redes *backpropagation* (backpropagation feedforward networks) se han convertido en la elección estándar para modelos, predicciones y clasificaciones (Klimasauskas, 1991b). En ellas los PEs alcanzan un nivel de actividad interna sumando las entradas ponderadas por los pesos de sus conexiones. Entonces la suma se modifica con una función de transferencia continua no lineal, generalmente una sigmoide, y pasa a la conexión de salida del PE (NeuralWare Inc., 1991).

La regla de aprendizaje en estas redes es la "regla delta generalizada" desarrollada por Rumelhart *et al.* (1986). El aprendizaje se produce en la etapa de entrenamiento y los pesos permanecen inalterables posteriormente durante el funcionamiento normal de la red. Una red *backpropagation* utiliza los datos de entrada para calcular su propio resultado, entonces lo compara con el resultado deseado. Si no hay error, no hay aprendizaje (Rumelhart *et al.*, 1986). Si el resultado es erróneo, la red asume que la "culpa" es de todos los PEs y conexiones. Para reducir la diferencia entre el resultado actual y el correcto, se cambian los pesos de las conexiones propagando el error cometido hacia atrás, a través de las conexiones con el nivel anterior al de salida (NeuralWare Inc., 1991). El proceso iterativo de presentación de pares entrada/salida a la red y alteración de conexiones se continúa hasta que se encuentra un conjunto de pesos que produce error nulo (o lo suficientemente próximo a cero, como 0,001) para todos los pares presentados. La red, se dice entonces, converge (NeuralWare Inc., 1991).

Comparación entre modelos

El modelo logit presentado es uno de los varios métodos estadísticos que puede aproximar funciones o describir relaciones con precisión. La ventaja de las ANN es que no

requieren asumir una determinada distribución en los datos de entrada, y permiten efectos de interacción entre variables y no linealidad en los datos (NeuralWare Inc., 1991), por tanto, pueden ser más robustas y predecir mejor que los modelos estadísticos cuando se estudian relaciones no lineales y distribuciones no normales (NeuralWare Inc., 1989; Cook *et al.*, 1991). En algunas aplicaciones, las ANN han conseguido reducir drásticamente los errores de predicción o clasificación; en otras donde el problema estaba muy bien definido, sólo igualan o aproximan el modelo estadístico alternativo desarrollado para dicho problema (Klimasauskas, 1991a). Las aplicaciones recientes de las ANN en el campo de los recursos naturales son muy numerosas y están relacionadas con el análisis de tendencias y patrones en general (Klimasauskas, 1991a; Hilera y Martínez, 1995). La selección del modelo backpropagation como alternativa al modelo logit en este estudio obedeció a nuestro deseo de evaluar las redes neuronales para la predicción de incendios forestales originados por agentes de ignición humanos y compararlas con un método estadístico más tradicional.

Construcción de los modelos

Se utilizó ARC/INFO (ESRI Inc., 1991) para cartografiar ocho unidades de predicción de ocurrencia de incendios forestales en el área de estudio. Cada uno de los cuatro distri-

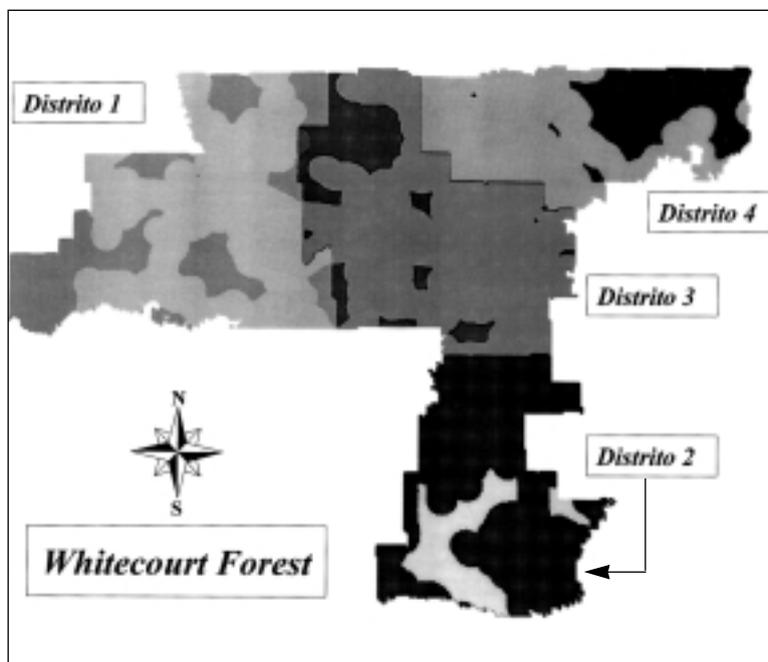


Fig. 2.-Las ocho unidades geográficas de predicción de incendios en Whitecourt Forest
The eight fire occurrence prediction units for the analysis in Whitecourt Forest

tos forestales de Whitecourt fue dividido en dos zonas: el área a menos (\leq) de 5 km de un carretera, y el área más de 5 km de una carretera (Fig. 2). Se sabía que el 90 % de los incendios por causas humanas en Whitecourt comienzan a menos de 5 km de cualquier carretera (Vega García *et al.*, 1993). Se esperaba que esta partición incrementara la variabilidad de las variables geográficas para el análisis, a la vez que se mantenía bajo el número de unidades de predicción. Las unidades de predicción variaban en área entre 805 y 4.660 km².

Cada unidad de predicción fue codificada, usando ARC/INFO e información digital de diferentes fuentes (Vega García *et al.*, 1993), con las variables de la Tabla 1. La variable *df* de valor 1 para unidades en el distrito forestal 2, y 0 para unidades en los distritos 1, 3, ó 4, se incluyó porque el distrito 2 sufre una mayor presión humana y desarrollista y está más cercana a Edmonton, Alberta, que tiene una población superior a 500.000 habitantes.

Las variables meteorológicas diarias asignadas a cada unidad se obtuvieron como promedio de los valores disponibles en las estaciones de cada distrito, y se listan en la Tabla 2. La variable lógica *mes* de valor 1 en días de Abril y Mayo, y valor 0 en días de Junio a Octubre se introdujo para capturar tendencias estacionales en ocurrencia de incendios en Whitecourt Forest (50 % de los incendios por causas humanas en 1986-1990 ocurrieron en primavera).

TABLA 1
VARIABLES GEOGRAFICAS ASIGNADAS A CADA UNIDAD DE PREDICCIÓN
Geographic variables assigned to each prediction unit

Abreviatura	Descripción	Unidades ¹
área	Area de la unidad de predicción	km ² /10.000
carrdis	Distancia media a carreteras en la unidad	km/100
urban	Distancia media a ciudades en la unidad	km/100
camp	Distancia media a áreas de acampada en la unidad	km/100
elev	Elevación topográfica media de la unidad	Metros sobre el nivel del mar/10.000
ppa	Area total de propiedad privada en la unidad	km ² /1.000
com	Area total forestal de valor comercial "altamente improductivo"	km ² /1.00
comb 1	Area total de frondosas en la unidad	km ² /10.000
comb 2	Area total de pastos en la unidad	km ² /100
comb 3	Area total de cortas en la unidad	km ² /100
carrlog	Variable lógica para unidad a <0> 5 km de carretera	1,0
df	Variable lógica para localización en distrito forestal 2 ó en 1, 3, 4	1,0

¹ Las variables numéricas se escalaron para obtener estimadores de los parámetros en el mismo orden de magnitud. *Numeric variables were scaled down to obtain parameter estimates in the same order of magnitude.*

TABLA 2
VARIABLES TEMPORALES ASIGNADAS A CADA UNIDAD
DE PREDICCIÓN, DIARIAMENTE

Temporal variables assigned to each prediction unit, each day

Abreviatura	Descripción	Unidades ¹
FFMC	Fine Fuels Moisture Code ²	Escala abierta/100
DMC	Duff Moisture Code ²	Escala abierta/100
ISI	Initial Spread Index ²	Escala abierta/10
BUI	Build-up Index ²	Escala abierta/100
FWI	Fire Weather Index ²	Escala abierta/100
Humedad	Humedad relativa	Porcentaje/100
Viento	Velocidad del viento	(km/h)/100
Mes	Variable lógica para día de primavera o no	1,0

¹ Las variables numéricas se escalaron para obtener estimadores de los parámetros en el mismo orden de magnitud. *Numeric variables were scaled down to obtain parameter estimates in the same order of magnitude.*

La base de datos del análisis incluía observaciones diarias en las campañas de incendios 1986-1990 (Abril - Octubre), en cada una de las unidades descritas (± 200 días/año \times 5 años \times 8 unidades = 8.009 observaciones). La variable dependiente binaria *ocur* recibió un valor de 1 si ocurrió al menos un incendio en la unidad y día de observación, y un valor de 0 si no hubo incendio. De las 8.009 observaciones, sólo 157 eran observaciones con incendios.

El modelo logit

Como el modelo logit no se ve afectado por proporciones de muestreo diferentes en sus datos (Maddala, 1988; Prentice, 1986), se obtuvo una muestra aleatoria de 157 observaciones sin incendios que se unieron a las 157 observaciones con incendios para la construcción del modelo logit.

Se empleó el módulo LOGISTIC de SAS (SAS Institute Inc., 1989) para calcular los posibles modelos. Se construyeron 88 modelos, todos en forma lineal, siguiendo las recomendaciones de Cox, Snell (1989), Hosmer, Lemeshow (1989) para la construcción de modelos con un gran número de variables explicatorias. Se aplicaron tres criterios para comparar la utilidad de los modelos logit desarrollados:

1. Criterios basados en los parámetros estimados.

Primero, se examinaron los signos y magnitudes de los estimadores para comprobar que coincidían con las expectativas basadas en experiencias previas. Además, se usaron los valores del test χ^2 y del estadístico de Wald (Ben-Akiva y Lerman, 1985) para evaluar si los parámetros estimados eran significativos.

2. Criterios basados en la bondad de ajuste de los modelos a los datos.

Loftsgaarden y Andrews (1992) recomiendan el uso del test de bondad de ajuste de Hosmer y Lemeshow (1989) para evaluar ajuste en modelos con dos ó más variables. El programa LOGISTIC calculó este test, junto con el más corriente test de cociente de probabilidad (likelihood ratio test), y los estadísticos del criterio de Akaike y del criterio de Schwartz (SAS Institute Inc., 1989), que se utilizaron como criterios secundarios.

3. Criterios basados en la capacidad predictiva de los modelos.

Las capacidades predictivas de los modelos se evaluaron con tablas de clasificación de respuestas observadas y predichas 2x2 (Tabla 3) (SAS Institute Inc., 1989). El porcentaje total de observaciones predichas correctamente se calcula como $A+D/A+B+C+D$:

El análisis de observaciones influyentes y outliers (puntos extremos) se realizó de acuerdo a los diagnósticos de regresión logarítmica desarrollados por Pregibon (1981).

TABLA 3

TABLA DE CLASIFICACION DE RESPUESTAS OBSERVADAS Y PREDICHAS

Classification table of observed and predicted responses

Frecuencias/porcentajes de fila	Predicho No Incendio	Predicho Incendio
Observado No Incendio	A Especificidad	B Falsos Positivos
Observado Incendio	C Falsos Negativos	D Sensibilidad

Construcción del modelo backpropagation

Se utilizaron los mismos datos en este análisis que en el modelo logit asegurando así la comparación de los resultados. Se intentó primero el desarrollo de un modelo de red a partir de las 20 variables temporales y geográficas. Las variables no relevantes serían eliminadas en el proceso de desarrollo de la red, mediante análisis de sensibilidad de los inputs.

Guiver y Klimasauskas (1991) advierten que cuanto menos información superflua se dé a la red, mayor será su capacidad de hallar las verdaderas relaciones en los datos. Estos autores recomiendan el uso de expertos para seleccionar las entradas a la red. Por esta razón, se desarrollaron también dos redes equivalentes a los dos mejores modelos logit (modelos 1 y 2) utilizando sus mismas variables como entradas. En este caso, el análisis logit proporcionó la experiencia necesaria para la selección de los inputs.

Se utilizó el programa NeuralWorks Professional II/plus (NeuralWare Inc., 1991) para simular el desarrollo de las redes. Esta herramienta permitió la experimentación de diferentes arquitecturas para las redes, de diferentes parámetros de la regla de aprendizaje, y de funciones varias de transferencia en los PEs. Se siguió el procedimiento general descrito por Klimasauskas (1991a) para el desarrollo de una red neural.

Análisis exploratorios previos indicaron que los mejores resultados para el problema de los incendios podrían alcanzarse seleccionando la función de transferencia sigmoidea y la regla delta generalizada. Para acelerar la fase de entrenamiento se utilizó una variación rápida del algoritmo de retro-propagación (Fast Back-propagation) (NeuralWare Inc., 1991).

Se probaron diferentes arquitecturas para las redes, todas con un sólo nivel oculto, suficiente para resolver la mayoría de los problemas (Klimasauskas, 1991c). En todas estas arquitecturas un nivel cualquiera estaba completamente conectado al nivel anterior, pero no se permitió que las conexiones saltaran niveles, ya que el análisis previo no mostró que esto mejorara las redes. Terminado el proceso de aprendizaje, se emplearon tablas de clasificación de las respuestas observadas y predichas para seleccionar la mejor red de cada grupo de igual arquitectura.

RESULTADOS

El modelo logit

Ninguna de las 314 observaciones utilizadas en el análisis se consideró desechable según los diagnósticos de Pregibon (1981), por ello no se extrajo ninguna en la construcción de ningún modelo. Se eligió un modelo de cuatro variables (*area*, *df*, *BUI*, *ISI*) como el mejor en base a sus buenos resultados en la mayoría de los criterios de selección, que denominamos modelo logit 1.

Los valores y signos de los coeficientes estimados fueron significativos al nivel 0,05 y acordes a las expectativas teóricas. El test de bondad de ajuste de Hosmer, Lemeshow (1989) mostró un ajuste adecuado del modelo a los datos ($\chi^2 = 10,94$, p-value 0,2051). Este modelo clasificó correctamente el 79,0 % de todas las observaciones (Tabla 4).

TABLA 4

TABLA DE CLASIFICACION PARA LOS DATOS DE CONSTRUCCION DEL MODELO LOGIT 1 (1986-1990)

Classification table for the model building data (1986-1990): Logit model 1

Frecuencias/Porcentajes de fila	Predicho No Incendio	Predicho Incendio
Observado No Incendio	128 81,5 %	29 19,5 %
Observado Incendio	37 22,4 %	120 76,4 %

Los coeficientes para el modelo 1 se estimaron a partir de grupos con tasas de muestreo desiguales ($P_1=157/157$ para días con incendios, $P_2=157/7852$ para días sin incendios), por tanto era necesario proceder al ajuste del modelo antes de poder usarlo para la predicción de incendios (Maddala, 1988). Después de sustraer el valor de corrección del término independiente β_0 ($3,9122 = \ln(157/157)-\ln(157/7852)$), la probabilidad P_i de que ocurra al menos un incendio en cualquier unidad de predicción en Whitecourt Forest, un día cualquiera, puede determinarse mediante la ecuación [2]:

$$\ln \left(\frac{P_i}{1 - P_i} \right) = -8,517 + 7,659 * \text{area}_i + 0,737 * \text{df}_i + 2,048 * \text{BUI}_i + 3,956 * \text{ISI}_i \quad [2]$$

Se utilizaron nuevos datos de incendios de 1991-1992 para validar el modelo logit 1 con observaciones independientes. Estos nuevos datos incluían 3.294 observaciones de las que sólo 58 contenían incendios. Se calculó una tabla de clasificación (Tabla 5) para la validación. El cálculo de las tablas de clasificación generalmente implica el establecimiento de un nivel de probabilidad o punto de corte para segregar observaciones en sucesos probables y sucesos improbables (Schuster, 1983; Jamnick y Beckett, 1987). Ese nivel se fija generalmente en 0,5 que es el punto medio de la distribución logarítmica.

TABLA 5

TABLA DE CLASIFICACION DEL MODELO LOGIT 1 PARA DATOS DE 1991-1992

Classification table for the model 1 on an independent data set (1991-1992)

Frecuencias/Porcentajes de fila	Predicho No Incendio	Predicho Incendio
Observado No Incendio	2.398 74,14 %	838 25,90 %
Observado Incendio	15 25,86 %	43 74,10 %

Sin embargo, este punto de corte es arbitrario, y depende en última instancia de los objetivos del modelo y del usuario (Jamnick y Beckett, 1987). Una decisión sobre el "mejor" nivel de probabilidad implica una elección entre predecir correctamente los días con incendios o predecir correctamente los días sin incendios (Schuster, 1983; Jamnick y Beckett, 1987). Schuster (1983) ha señalado que este problema es similar al problema estadístico de error de Tipo I versus error de Tipo II. El objetivo de este estudio era obtener una precisión semejante en la predicción de días con y sin incendios. Definiendo un nivel de probabilidad arbitrario de 0,02 en la tabla de clasificación del modelo 1 para los datos de 1991-1992 (Tabla 5), se clasificaron correctamente 74,10 % del número total de nuevas observaciones, 74,14 % de los días con incendios, y 74,10 % de los días sin incendios.

El modelo backpropagation

El aprendizaje se completó en 19.000 interacciones en la mayoría de las redes. El conjunto total de las observaciones se presentó a las redes unas 60 veces, cada vez en un orden diferente. Los pesos de las conexiones aumentaron a velocidad parecida durante el proceso, adoptando forma de campana en su histograma. Esto y el lento descenso del error producido en el nivel de salida sugieren un buen comportamiento de las redes. El programa proporciona varios gráficos o instrumentos para seguir el proceso de aprendizaje en pantalla, evaluando el error que comete la red y la distribución que siguen los pesos. Estos instrumentos se muestran en la Figura 3 para la mejor red.

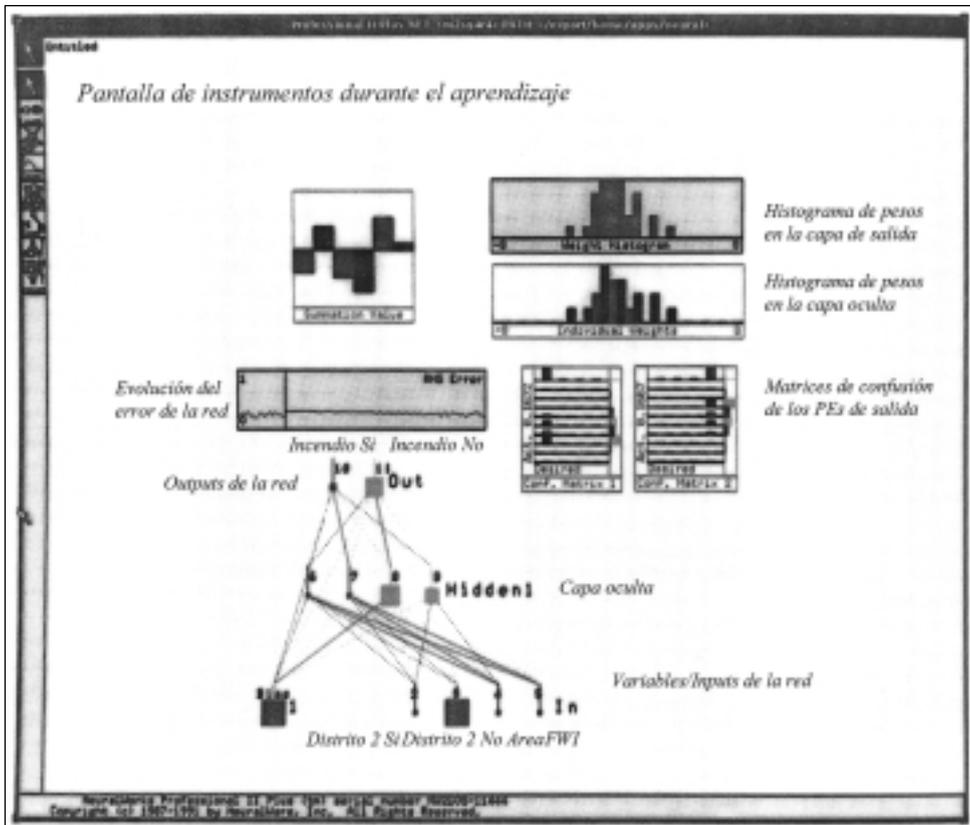


Fig. 3.—Mejor red neuronal e instrumentos de control del aprendizaje
Best neural network model, and instruments provided to monitor and evaluate training

La mejor de las redes tenía como variables de entrada *área*, *df* y *FWI*, las variables del segundo mejor modelo logit. Esta red fue capaz de predecir correctamente 85 % (133) de los días sin incendios y 78 % (122) de los días con incendios. El porcentaje total de pre-

dicciones correctas fue del 81 %. La tabla de clasificación para los datos de entrenamiento se presenta en la Tabla 6.

TABLA 6
TABLA DE CLASIFICACION DE LA MEJOR RED PARA
LOS DATOS DE ENTRENAMIENTO (1986-1990)

Classification table for the best neural net model on the training data set (1986-1990)

Frecuencias/Porcentajes de fila	Predicho No Incendio	Predicho Incendio
Observado No Incendio	133 84,71 %	24 15,29 %
Observado Incendio	35 22,29 %	122 77,70 %

Para los datos de validación o test -las mismas 3.294 observaciones de 1991-1992 que se utilizaron para evaluar el modelo logit 1- el porcentaje total de predicciones correctas, fue de 76 %. La red clasificó correctamente 76 % de los días sin incendios y 75,8 % de los días con incendios en 1991-1992. Su tabla de clasificación se presenta en la Tabla 7.

TABLA 7
TABLA DE CLASIFICACION DEL MEJOR MODELO DE RED
PARA DATOS DE 1991-1992

Classification table for the best neural net model on an independent data set (1991-1992)

Frecuencias/Porcentajes de fila	Predicho No Incendio	Predicho Incendio
Observado No Incendio	2.462 76,08 %	774 23,92 %
Observado Incendio	14 24,14 %	44 75,86 %

DISCUSION E IMPLICACIONES PARA LA GESTIÓN

El porcentaje total de predicciones correctas de la mejor red superó sólo en un 2 % al porcentaje del mejor modelo logit construido, para un conjunto de datos independientes de la construcción de ambos modelos. El hecho de que dos técnicas muy diferentes alcanzaron casi idéntica precisión en la predicción de incendios en Whitecourt Forest podría indi-

car limitaciones en los datos, más que en las técnicas utilizadas para desarrollar los modelos. Así, por ejemplo, los mejores modelos de ambos tipos no incluyen ninguna variable geográfica, aún cuando se haya demostrado que varias de ellas están relacionadas significativamente con la ocurrencia de incendios (Chou *et al.*, 1993; Vega García *et al.*, 1993). El escaso rango de sus valores puede haber enmascarado la verdadera importancia de las variables geográficas.

Sin embargo los resultados proporcionados por ambos modelos se pueden considerar satisfactorios y sus escasos requerimientos de entrada de datos deberían facilitar su cálculo diario y la actualización de los modelos en el futuro, que dependerá de las tendencias en la ocurrencia de incendios. En su aplicación para la predicción, sin embargo, deben hacerse algunas consideraciones:

1. En días fuera del período de cálculo de los índices de peligro canadiense (finales de Marzo, por ejemplo), no se pueden formular predicciones. Aún así, los incendios fuera de campaña en Whitecourt son pocos y fáciles de controlar.
2. La predicción que se obtiene es sólo Incendio(s) Sí/No para cada día y unidad de predicción, lo cual es suficiente en Whitecourt, ya que en el período 1986-1990, hubo sólo un incendio por unidad y día en la mayoría de los casos (124 de 157).
3. Si se desea, puede calcularse la probabilidad de que ocurran N incendios en una unidad según el proceso descrito por Martell *et al.* (1987), basado en la distribución de Poisson. Estos autores también determinaron la probabilidad de ocurrencia de al menos un incendio con un modelo logit, utilizando índices del sistema canadiense como variables. Su criterio de selección de modelos (*average score*), sin embargo, ha sido criticado por Loftsgaarden y Andrews (1992), que establecieron que este test no indica verdaderamente la bondad de los modelos o lo bien que se ajustan a los datos. Loftsgaarden y Andrews (1992) recomendaban el test de Hosmer, Lemeshow (1989) en su lugar, consejo que se ha seguido en este estudio. También es posible construir redes que proporcionen una predicción del número diario de incendios si se cuenta con datos suficientes para entrenarlas.
4. La actuación del modelo logit depende del valor de probabilidad elegido en la tabla de clasificación. El valor 0,02 fue seleccionado arbitrariamente para obtener la misma precisión en predecir días con y sin incendios. Este nivel de probabilidad podría y debería ser seleccionado según los objetivos de la agencia de incendios que utilice el modelo. Un valor más alto (menos falsas alarmas y menor precisión en días con incendios) puede preferirse si: (1) no hay muchos recursos de extinción disponibles, (2) si resulta caro activarlos, (3) si no se requieren altos niveles de protección para las zonas a proteger. Un punto de corte más bajo (más precisión en la predicción de incendios, pero también más falsas alarmas) puede ser preferible para un área donde los valores en riesgo sean altos y haya abundantes recursos de extinción, disponibles rápidamente. En este caso, las falsas alarmas serían menos problemáticas que un incendio fuera de control. Deberían utilizarse consideraciones económicas para determinar el nivel de precisión a usar en cada caso.
5. Un modelo que sobreestime sistemáticamente el número de días con incendios o produzca muchas falsas alarmas tiene una credibilidad reducida cuando se aplica operativamente a la predicción. Las falsas alarmas, sin embargo, se producirán de vez en

cuando, sea cual sea el modelo o el punto de corte elegido para separar días con y sin incendios. Las redes neuronales se pueden "afinar" para reducir los falsos positivos o negativos usando tablas de error especiales en el aprendizaje (Klimasauskas, 1991d). Esta es una ventaja que poseen sobre los modelos logit, aunque su inclusión en este análisis se consideró fuera del ámbito del estudio.

6. Las predicciones de incendios futuros (el día siguiente, por ejemplo) dependen de la predicción de los valores futuros de los índices del FWI. Los usuarios deberían tener presente el efecto que una predicción meteorológica puede tener sobre éste y otros modelos de predicción (Tithecott, 1993).

Ninguna de estas consideraciones impide la utilización de este tipo de modelos dentro de sus límites de aplicabilidad.

CONCLUSIONES

Se desarrollaron satisfactoriamente dos tipos de modelos para la predicción diaria de incendios forestales por causas humanas en Whitecourt Forest. Las predicciones de la red neuronal fueron algo mejores que las del modelo logit, ya que la mejor red superó al mejor modelo logit en la tabla de clasificación de respuestas observadas y predichas. La mejora, sin embargo, no se juzga suficiente para compensar el mayor coste de computación que implica el desarrollo de una red. Además, esta red se benefició de la selección de variables realizada por el análisis estadístico tradicional, lo cual confirma aparentemente la importancia de la experiencia en la selección de inputs mencionada por Guiver y Klimasauskas (1991). La prevención de los usuarios hacia las redes neuronales, que se perciben como "cajas negras", también parece favorecer el uso de modelos logit sobre el de redes neuronales en estos momentos.

Sin embargo, no se exploró todo el potencial de la tecnología de redes neuronales en este estudio. Hay muchos tipos de redes y reglas de aprendizaje desarrolladas específicamente para la predicción. El problema es que hay una carencia general de referencias bibliográficas en el uso de estas redes. El proceso de construcción de una red es todavía más un arte que una técnica, incluso dejando aparte la dificultad de seleccionar las variables de entrada. A medida que esta tecnología vaya evolucionando, podemos esperar que muchas aplicaciones se beneficien de lo que Klimasauskas (1991a) llama "su habilidad para aproximar relaciones matemáticamente complejas". Este estudio sugiere que la predicción de incendios será una de esas aplicaciones.

AGRADECIMIENTOS

Este estudio fue posible gracias al apoyo de las instituciones siguientes: Ministerio de Educación y Ciencia de España, Universidad de Alberta, Servicio Forestal Canadiense (Canadian Forestry Service, CFS) y Servicio Forestal de Alberta (Alberta Forest Service, AFS). Agradecemos especialmente la asistencia profesional y técnica del personal del CFS en Edmonton y de Mag Steiestol (AFS), y los comentarios de un evaluador anónimo de la revista.

SUMMARY

Two models for fire occurrence prediction in Whitecourt Forest, Canadá

This study models the daily human-caused wildfire occurrence in Whitecourt Forest, Alberta, Canada. Two models were developed, a logit model and a neural network model. Both achieved similar accuracy when applied to daily prediction (74 vs. 76 %). This paper describes the methods used for the models development and discusses the management implications and limitations of the study.

KEY WORDS: Human-caused
Forest fire occurrence
Prediction
Canada

REFERENCIAS BIBLIOGRAFICAS

- ALBERTA ENERGY AND NATURAL RESOURCES, 1985. Alberta Phase 3 Forest Inventory: forest cover type specifications. Alberta Forest Service, Resource Evaluation and Planning Division, Edmonton, Alberta, Canada. ENR Report n. dept. 58, 53 pp.
- BEN-AKIVA M., LERMAN S.R., 1985. Discrete Choice Analysis: Theory and application to travel demand. The MIT Press, Cambridge, Massachusetts, USA, 390 pp.
- CHOU H.Y., MINNICH R.A., SALAZAR L.A., POWER J.D., DEZZANI R.J., 1990. Spatial autocorrelation of wildfire distribution in the Idyllwild Quadrangle, San Jacinto Mountains, California. Photogrammetric Engineering & Remote Sensing 56, 1507-1513.
- CHOU Y.H., MINNICH R.A., CHASE R.A., 1993. Mapping probability of fire occurrence in San Jacinto Mountains, California, USA. Environmental Management 17(1), 129-140.
- COOK D.F., MASEY J.G., SHANNON R.E., 1991. A neural network to predict particleboard manufacturing process parameters. Forest Science 37, 1463-1478.
- COX D.R., SNELL E.J., 1989. Analysis of binary data. Second Edition. Chapman and Hall, New York, New York, USA, 236 pp.
- CUNNINGHAM A.A., MARTELL D.L., 1976. The use of subjective probability assessments to predict forest fire occurrence. Canadian Journal of Forest Research 6, 348-356.
- ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE, 1991. Understanding GIS: the ARC/INFO method. Environmental Systems Research Institute Inc., Redlands, California, USA.
- GUIVER J.P., KLIMASAUSKAS C.C., 1991. Applying neural networks. Part IV: Improving performance. PC Artificial Intelligence July/August 1991, 34-41.
- HILERA J.R., MARTÍNEZ V.J., 1995. Redes neuronales artificiales: Fundamentos, modelos y aplicaciones. Serie Paradigma, RA-MA Editorial, Madrid, 390 pp.
- HOSMER D.W. Jr., LEMESHOW S., 1989. Applied logistic regression. John Wiley & Sons, New York, New York, USA, 307 pp.
- JAMNICK M.S., Beckett D.R., 1987. A logit analysis of private woodlot owner's harvesting decisions in New Brunswick. Canadian Journal of Forest Research 18, 330-336.
- KLIMASAUSKAS C.C., 1991a. Applying neural networks. Part I: An overview of the series. PC Artificial Intelligence January/February 1991, 30-33.
- KLIMASAUSKAS C.C., 1991b. Applying neural networks. Part II: A walk through the application process. PC Artificial Intelligence March/April 1991, 27-34.
- KLIMASAUSKAS C.C., 1991c. Applying neural networks. Part III: Training a neural network. PC Artificial Intelligence May/June 1991, 20-24.
- KLIMASAUSKAS C.C., 1991d. Applying neural networks. Part IV: Special Topics. PC Artificial Intelligence November/December 1991, 46-49.
- LOFTSGAARDEN D.O., ANDREWS P.L., 1992. Constructing and testing logistic regression models for binary data: Applications to the National Fire Danger Rating System. USDA Forest Service, Intermountain Research Station, General Technical Report INT-286, 36 pp.
- MADDALA G.S., 1983. Limited-dependent and qualitative variables in econometrics. Econometric Society monographs; 3. Cambridge University Press, New York, New York, USA, 401 pp.

- MADDALA G.S., 1988. Introduction to econometrics. Macmillan Publishing Co., New York, New York, USA, 412 pp.
- MARTELL D.L., OTUKOL S., STOCKS B.J., 1987. A logistic model for predicting daily people-caused fire occurrence in Ontario. *Canadian Journal of Forest Research*. 17, 394-401.
- MERRILL D.F., ALEXANDER M. E., eds., 1987. Glossary of forest fire management terms, Fourth edition. National Research Council of Canada, Canadian Committee on Forest Fire Management, Ottawa, Ontario, Canada. Publication NRCC N. 26516, 91 pp.
- NEURALWARE Inc., 1989. Applying neural networks in bussiness, industry and government. NeuralWare Training Group, Pittsburgh, Pennsylvania. USA.
- NEURALWARE Inc., 1991. Neural Computing. NeuralWorks Professional II/plus and NeuralWorks Explorer. NeuralWare Training Group, Pittsburgh, Pennsylvania, USA. 358 pp.
- PHILLIPS C., NICKEY B., 1978. The concept of "Spatial Risk" and its application to Fire Prevention. *Fire Management Notes*, 39(4), 7-8,19.
- PREGIBON D., 1981. Logistic Regression Dignostics. *The Annals of Statistic* 9(4), 705-724.
- PRENTICE R.L., 1986. A case-cohort design for epidemiologic cohort studies and disease prevention trials. *Biometrika* 73, 1-11.
- RUMELHART D.E., HINTON G.E., WILLIAMS R.J., 1986. Learning internal representations by error propagation. In: Parallel distributed processing: Explorations in the microstructures of cognition, vol. 1: Foundations. Rumelhart, D.E. y J.L. McClellan, eds. The MIT Press, Cambridge, Massachussets, USA.
- SAS INSTITUTE INC., 1989. SAS/STAT User's Guide, Version 6, Fourth Edition, Volume 2, Cary, North Carolina: SAS Institute Inc., 846 pp.
- SIMARD A.J., 1973. Forest fire weather zones of Canada. Environment Canada. Canadian Forestry Service. Map.
- SCHUSTER E.G., 1983. Evaluating nonindustrial private landowners for forestry assistance programs: a logistic regression approach. USDA Forest Service, Intermountain Forest and Range Experiment Station, Research Paper INT-320, 7 pp.
- STRONG W.L., LEGGAT K.R., 1981. Ecoregions of Alberta. Alberta Energy and Natural Resources, ENR Technical Report Number T/4, Edmonton, Canada.
- STYNES D.J., PETERSON G.L., 1984. A review of logit models with implications for modeling recreation choices. *Journal of Leisure Research* 16, 295-310.
- TITHECOTT A.G., 1993. Application of fire occurrence prediction models in Ontario's fire management program. In: Proceedings of the Ninth Central Region Fire Weather Committee Scientific and Technical Seminar, Winnipeg, Manitoba, Canada, April 3, 1992, vol.1, 57-72. Anderson, K.R., ed. Forestry Canada, Northwest Region, Northern Forestry Centre, Edmonton, Alberta, Canada, 78 pp.
- TODD B., KOURTZ P.H., 1991. Predicting the daily occurrence of people-caused forest fires. Forestry Canada, Petawawa National Forestry Institute, Chalk River, Ontario, Canada. Information Report PI-X-103, 16 pp.
- VAN WAGNER C.E., 1987. Development and structure of the Canadian Forest Fire Weather Index System. Government of Canada, Canadian Forestry Service, Ottawa, Ontario, Canada. Forestry Technical Report n. 35, 36 pp.
- VEGA GARCÍA C., WOODARD P.M., LEE B.S., 1993. Geographic and temporal factors that seem to explain human-caused fire occurrence in Whitecourt Forest, Alberta. In: Proceedings GIS'93 Symposium, Vancouver, British Columbia, Canada, Feb 1993, vol 1, 115-119.
- VEGA GARCÍA C., 1994. Predicting human-caused forest fire occurrence in Whitecourt Forest, Alberta. M.Sc Thesis. University of Alberta, Edmonton, Canada. 117 pp.