



UNIVERSIDAD AUTÓNOMA CHAPINGO



DIVISIÓN DE CIENCIAS FORESTALES

MAESTRÍA EN CIENCIAS EN CIENCIAS FORESTALES

PROYECCIONES HASTA EL AÑO 2100 DE VARIABLES CLAVE EN EL SECTOR FORESTAL DE MÉXICO Y SU ANÁLISIS EN LA POLÍTICA PÚBLICA

TESIS

Que como requisito parcial
para obtener el grado de:

MAESTRO EN CIENCIAS EN CIENCIAS FORESTALES

Presenta:

JAVIER MEDINA HERNÁNDEZ

Bajo la supervisión de: DR. FRANCISCO JOSÉ ZAMUDIO SÁNCHEZ

Chapingo, Estado de México, México, a mayo del 2020.



MAESTRÍA EN CIENCIAS EN
CIENCIAS FORESTALES

**PROYECCIONES HASTA EL AÑO 2100 DE VARIABLES CLAVE
EN EL SECTOR FORESTAL DE MÉXICO Y SU ANÁLISIS
EN LA POLÍTICA PÚBLICA**

Tesis realizada por **JAVIER MEDINA HERNÁNDEZ** bajo la supervisión del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS EN CIENCIAS FORESTALES

DIRECTOR:



DR. FRANCISCO JOSÉ ZAMUDIO SÁNCHEZ

CO-DIRECTOR:



DR. ALEJANDRO ISMAEL MONTERROSO RIVAS

ASESOR:



DR. GABRIEL ARCÁNGEL RODRÍGUEZ YAM

ASESOR:



DRA. ADRIANA ÁVALOS VARGAS

Chapingo, Estado de México, México, a mayo del 2020.

CONTENIDO

CONTENIDO	iii
LISTA DE CUADROS	vi
LISTA DE FIGURAS	vi
LUCUBRACIONES	xiii
DEDICATORIA	xiv
AGRADECIMIENTOS	xv
DATOS BIOGRÁFICOS	xviii
RESUMEN GENERAL	xix
GENERAL ABSTRACT	xx
1 INTRODUCCIÓN GENERAL	1
1.1 Objetivos.....	2
1.1.1 <i>Objetivo general:</i>	2
1.1.2 <i>Objetivos particulares:</i>	3
1.2 Literatura citada	3
2 REVISIÓN DE LITERATURA	6
2.1 Sector forestal.....	6
2.1.1 <i>Situación mundial</i>	6
2.1.2 <i>Los bosques de México: pasado, presente y futuro</i>	8
<i>El pasado del sector forestal de México</i>	8
<i>Situación actual de los bosques de México</i>	9
<i>Perspectivas del sector forestal mexicano</i>	10
2.2 Series de tiempo.....	11
2.2.1 <i>Características generales</i>	11
2.2.2 <i>Tipos de series de tiempo</i>	12
2.2.3 <i>Análisis univariado de series de tiempo</i>	16

2.2.4	<i>Análisis multivariado de series de tiempo</i>	18
2.3	Métodos para proyectar series de tiempo.....	20
2.3.1	<i>Métodos estadísticos tradicionales</i>	20
Naïve 1	21
Naïve 2	22
Naïve S	23
Media móvil individual	23
Suavizado exponencial simple	24
Suavizado exponencial doble	24
Suavizado exponencial ajustado a la tendencia	25
Damped	26
Theta	27
Media móvil integrada autorregresiva	29
2.3.2	<i>Métodos combinados</i>	31
2.3.3	<i>Métodos de aprendizaje automático</i>	31
Redes neuronales artificiales	32
Redes neuronales recurrentes	33
Redes neuronales artificiales LSTM	34
2.4	Análisis bibliométrico en Scopus®.....	34
2.5	Medidas de desempeño de la proyección.....	37
MSE	37
RMSE	37
MAPE	37
2.6	Literatura citada	38
3	ANÁLISIS DE DATOS DEL SECTOR FORESTAL DE MÉXICO Y EL	
	MUNDO	45
3.1	Resumen	45
3.2	Introducción	47

3.3	Materiales y métodos.....	48
3.4	Resultados y discusión	49
3.4.1	<i>Situación actual de los bosques del mundo</i>	49
3.4.2	<i>Pasado y presente del sector forestal de México</i>	56
3.5	Conclusiones	75
3.6	Literatura citada	76
4	 EL SECTOR FORESTAL DE MÉXICO HASTA EL AÑO 2100: PROYECCIONES Y ELEMENTOS PARA SU SEGUIMIENTO Y TOMA DE DECISIONES.....	80
4.1	Resumen	80
4.2	Introducción	82
4.3	Materiales y métodos.....	85
4.3.1	<i>Datos</i>	85
4.3.2	<i>Software y hardware</i>	85
4.3.3	<i>RNN-LSTM: diseño y funcionamiento</i>	86
4.3.4	<i>RNN-DLSTM: Arquitectura y parámetros generales utilizados</i>	91
4.3.5	<i>Ciclos de entrenamiento-proyección</i>	91
4.3.6	<i>Descripción de las proyecciones</i>	92
4.4	Resultados.....	92
4.4.1	<i>Desempeño de las proyecciones</i>	92
4.4.2	<i>Proyecciones de las variables al 2100</i>	93
4.5	Discusión	97
4.6	Conclusiones	102
4.7	Literatura citada	103
5	 CONCLUSIONES GENERALES	109

LISTA DE CUADROS

Cuadro 1. Los diez países con la mayor superficie, pérdida y ganancia forestal en el mundo.....	51
Cuadro 2. Superficie Forestal De México Organizada Por Ecosistemas Y Formaciones Forestales.....	57

LISTA DE FIGURAS

Figura 1. Crecimiento de la población del mundo y los continentes en el periodo 1950-2100. Fuente: Elaboración propia con datos de la ONU, 2019.	7
Figura 2. Ejemplo de serie de tiempo: Variación de la temperatura media mensual de México en el periodo: 1961 a 2018. En esta serie con estacionalidad y tendencia se observa que los datos proporcionan información sobre anomalías en la temperatura con respecto al periodo de referencia (1951-1980), la tendencia calculada tiende a ser positiva y se midió un aumento de un grado centígrado para el último lustro. Fuente: Elaboración propia con datos de FAOSTAT, 2019.	12
Figura 3. Precipitación total mensual de Chapingo, Texcoco, Edo. Méx. México. Las lluvias en general tienen una variación que hace similar a las mediciones de un año con otro. Fuente: Elaboración propia con datos de la Comisión Nacional del Agua (CONAGUA), 2020.....	13
Figura 4. Temperaturas medias mensuales de Chapingo, Texcoco, Edo. Méx. México. Las temperaturas en general son cíclicas, por lo que presentan similitud entre los periodos. Fuente: Elaboración propia con datos de la CONAGUA, 2020.	14

Figura 5. Población de México total y por sexo de 1950 al 2100. La serie de tiempo está elaborada con datos reales en el periodo 1950-2018 y proyecciones hasta el año 2100, además, se observa una tendencia positiva hasta el año 2050 y posterior a este máximo disminuye. Fuente: Elaboración propia con datos de la ONU, 2019. 15

Figura 6. Crecimiento del PIP per cápita de México. En muchas series de tiempo que se generan de variables de estudio en Economía son de este tipo. Fuente: Elaboración propia con datos del Banco Mundial, 2019. 15

Figura 7. Proyección de la esperanza de vida en México con intervalos de confianza al 95 %. Nota: Se utilizó el método ARIMA. Fuente: Elaboración propia con datos del Banco Mundial, 2019. 18

Figura 8. Diagrama de la arquitectura de una red neuronal artificial (ANN). Se da una representación general y simple de los pesos de las conexiones que se encuentran activas durante el entrenamiento o trabajo realizado. Es decir, no todas las neuronas se encuentran activas en el entrenamiento. Fuente: Elaboración propia con información de Graves, 2012. 33

Figura 9. Número de publicaciones encontradas en Scopus® de los métodos más utilizados en la predicción de series de tiempo. Redes neuronales: NN, Regresión: regression y Máquinas de vectores de soporte: SVM. Fuente: Elaboración propia con datos de Elsevier, 2020. 35

Figura 10. Documentos por área temática. Fuente: Elaboración propia con datos de Elsevier, 2020. 35

Figura 11. Documentos publicados por país. Fuente: Elaboración propia con datos de Elsevier, 2020. 36

Figura 12. Tipos de documentos publicados relacionados con las RNN-LSTM en la predicción de series de tiempo. Fuente: Elaboración propia con datos de Elsevier, 2020. 36

Figura 13. Área forestal global y por continentes. Fuente: Elaboración propia con datos de la FAO, 2016.	50
Figura 14. Los países con mayor extracción de madera en el año 2011. El porcentaje se estimó con relación al total mundial de 3 mil millones de m ³ . Fuente: Elaboración propia con datos de la FAO, 2016.	52
Figura 15. Los diez principales países con área forestal designada para la conservación de la biodiversidad en el año 2015. El porcentaje se obtuvo con relación a los 524 millones que se calcularon para este rubro a nivel mundial. Fuente: Elaboración propia con datos de la FAO, 2016.	53
Figura 16. Situación actual de los biomas del mundo: a) Áreas de bajo impacto en los diferentes biomas y b) intensidad de los impactos humanos. Fuente: Tomado de Jacobson (2018).....	54
Figura 17. Territorio de México dividido por uso del suelo en general y el grado de alteración de la vegetación forestal. Fuente: Elaboración propia con datos de la CONAFOR, 2018.....	58
Figura 18. Distribución de las formaciones forestales en México. Fuente: Mapa descargado del Sistema Nacional de Información y Gestión Forestal (SNIGF), 2018.....	59
Figura 19. Superficie forestal de México representada por las principales formaciones forestales. Fuente: Elaboración propia con datos de CONAFOR, 2018.	60
Figura 20. Porcentaje de degradación de las formaciones forestales de México. Fuente: Elaboración propia con datos de la CONAFOR, 2018.	61
Figura 21. Factores de daño que afectan el desarrollo del arbolado en los bosques de México. Fuente: Elaboración propia con datos de CONAFOR, 2018.	61

Figura 22. Proporción de los principales agentes causales de daño en la salud del arbolado por cada formación forestal de México. Fuente: Elaboración propia con datos de CONAFOR, 2018.	62
Figura 23. Porcentaje de las principales causas de impacto ambiental por cada una de las formaciones forestales de México. Fuente: Elaboración propia con datos de CONAFOR, 2018.	63
Figura 24. Cambios en la superficie forestal total, arbolada y no arbolada para el periodo 1993-2014. Fuente: Elaboración propia con datos de CONAFOR, 2018.	65
Figura 25. Variación en la superficie de las selvas, bosques y manglares de México en el periodo 1993-2014. Fuente: Elaboración propia con datos de la CONAFOR, 2018.	66
Figura 26. Variación en la superficie de las selvas, bosques y manglares de México en el periodo 1993-2014. Fuente: Elaboración propia con datos de la CONAFOR, 2018.	66
Figura 27. Producción forestal maderable y no maderable de México del periodo: 1986-2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019a.	68
Figura 28. Comparación de la producción forestal maderable acumulada entre los estados de México en el periodo 1990-2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.	69
Figura 29. Producción forestal maderable por entidad federativa para el periodo 1990-2017. *Los valores mostrados están ordenados en orden decreciente respecto a los datos del año 2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.	69
Figura 30. Producción forestal maderable de México por especie para el periodo 1990-1986. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.	70

Figura 31. Producción forestal no maderable acumulada de los estados, periodo 1990-2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.	71
Figura 32. Producción forestal maderable de México por producto, valor y volumen para el año 2016. Fuente: Tomado de SEMARNAT, 2016.	72
Figura 33. Producción forestal no maderable por entidad federativa para el periodo 1990-2017. * Los valores mostrados están ordenados en orden decreciente de izquierda a derecha, respecto a los datos del año 2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.	73
Figura 34. Existencias de madera en rollo en bosques y selvas. Fuente: Elaboración propia con datos de SEMARNAT, 2019a.	74
Figura 35. PIB del aprovechamiento forestal de México para el periodo 1993-2019. *2019: valor preliminar estimado con la media de 3 trimestres. Fuente: Elaboración propia con datos de INEGI, 2019.	75
Figura 36. Los dos hardware y software básicos para aprendizaje profundo. Fuente: Adaptado de Chollet, 2018.	86
Figura 37. Esquema detallado del funcionamiento de una unidad de SRNN y un bloque de RNN-LSTM. La unidad SRNN solo cuenta con una función de activación de entrada y un punto de derivación. Por su parte el bloque LSTM presenta funciones más complejas en la entrada, salida y las tres puertas del bloque: entrada, olvido y salida. Además, se caracteriza por la celda (el Carrusel de error constante), una función de salida y conexiones de mirilla. Las salidas del bloque se conectan de forma recurrente a las entradas y puertas del bloque y de otros bloques de las capas profundas de la red. Fuente: Adaptado de Greff et al., 2017.	87
Figura 38. Diagrama de la arquitectura de una red neuronal recurrente profunda (RNN-DLSTM) que se caracteriza por presentar varios bloques de una celda cada uno, que a la vez se encuentran unidos en varias capas ocultas;	

además, se presentan cinco unidades de entrada y una unidad de salida. En comparación con una red neuronal recurrente (RNN-LSTM) de una sola capa oculta, en la cual se muestran a detalle las conexiones de los datos de entrada (xt) y las conexiones recurrentes ($xt - 1$), en este caso se tienen cuatro unidades de entrada y una unidad de salida. Cada bloque de la RNN-LSTM presenta cuatro entradas: entrada a bloque y las tres puertas (entrada, olvido y salida). No se presentan todas las conexiones. Fuente: Elaboración propia con información de Greff et al., (2017); Sagheer y Kotb (2019); Graves (2012); Hochreiter y Schmidhuber (1997); y Adam et al. (2018). 90

Figura 39. Esquema de la técnica entrenamiento-proyección utilizada para obtener cada uno de los datos anuales proyectados. En cada uno de los datos anuales obtenidos se realizó un nuevo entrenamiento (θ) previo a la realización de su respectiva proyección (δ) para obtener el dato posterior. Fuente: Elaboración propia. 92

Figura 40. Medidas de evaluación del desempeño de la proyección de la SFA de México. Se observa que el error (loss) disminuye conforme pasan las épocas en el entrenamiento y se obtuvieron valores bajos en RMSE y PDE. Fuente: Elaboración propia. 93

Figura 41. Superficie forestal arbolada (SFA) de México con su proyección hasta el año 2100 e intervalos de confianza (IC). Se observa una evidente tasa constante de pérdida de la SFA, consecuencia de las actividades antropogénicas y la falta de políticas públicas enfocadas en promover la actualización e instrumentación de planes de manejo sostenibles y eficientes, adaptados a cada región del país. Fuente: Elaboración propia con datos de la FAO (2019) para el período: 1990-2015..... 94

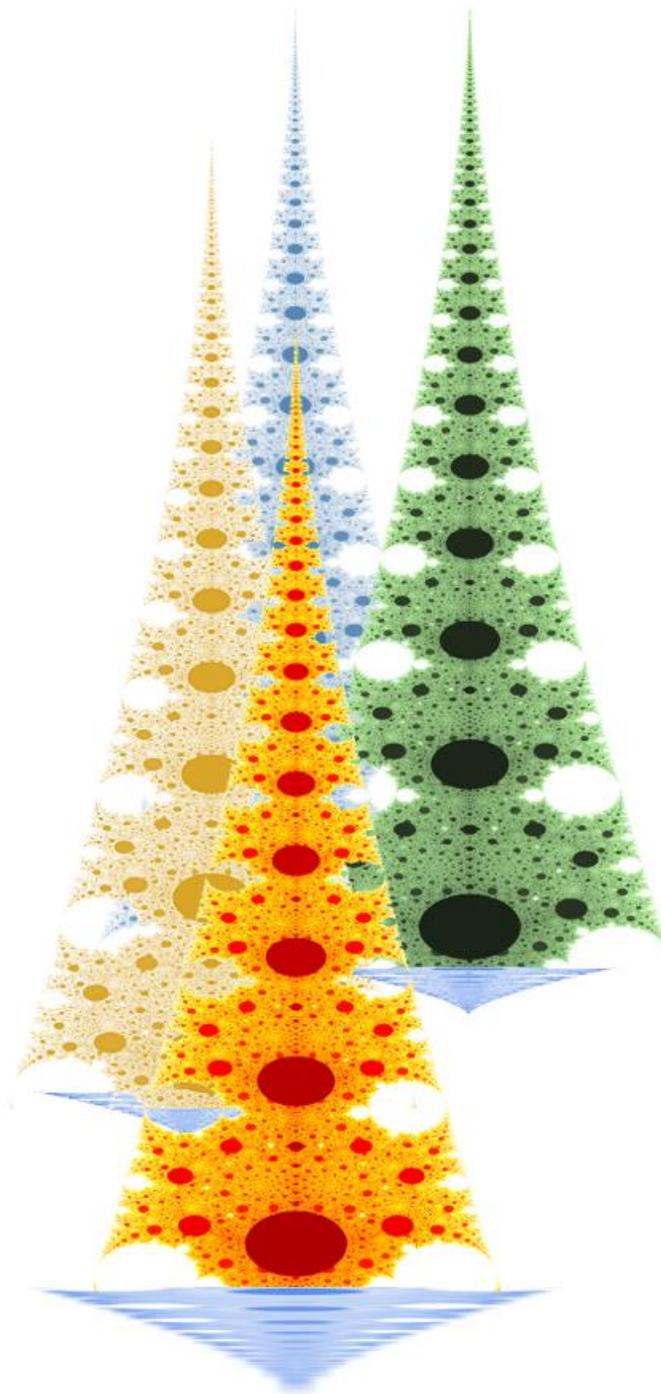
Figura 42. Producción forestal maderable (PFM) de México con su proyección hasta el año 2100. En la suma anual reportada se consideran el combustible de madera, trozas de aserrío y chapas, madera en pulpa, rollo y partida,

además de otra madera en rollo industrial. Se estima que, hasta el año 2100, la producción sea constante, como primer escenario, aunque es posible que se vea mermada por la sobreexplotación, la pérdida del área forestal, el crimen organizado, la demanda de una población en crecimiento, etcétera. Los avances tecnológicos, los planes de manejo sostenible y el manejo forestal comunitario podrían generar un aumento en la productividad del territorio nacional que actualmente se encuentra en producción. Fuente: Elaboración propia con datos de la FAO (2019) para el período: 1961-2018.

..... 95

Figura 43. Proyección de la importación forestal maderable (IFM) de México. Las importaciones y los productos forestales provenientes del contrabando son los que cubren una demanda cada vez mayor, que supera en más de tres veces la producción autorizada o legal (Chapela & Merino, 2019). De persistir con esta situación, es probable que las IFM aumenten durante el periodo 2018-2100. Fuente: Elaboración propia con datos de la FAO (2019) para el período: 1961-2018. 96

Figura 44. Exportación forestal maderable (EFM) de México y su proyección hasta el año 2100. Con los datos del pasado, se evidencia que México no es un país con un índice alto de exportaciones, debido, en gran medida, a la pérdida de competitividad que existe con relación al comercio internacional. A pesar de ello, en los últimos años se ha visto un alza importante que supero en más de seis veces a la media de las décadas anteriores, por lo que es muy posible que se siga registrando aumentos importantes en esta actividad. Los factores que desarrollarán las EFM son: la eficiencia en la producción, productividad y comercialización. Fuente: Elaboración propia con datos de la FAO (2019) para el período: 1975-2018. 97



Lucubraciones

*Soy presa fácil
de mis creencias y ambiciones.*

*Pero... ¿Qué puede hacer
un mortal que solo ve
el presente
e ignora en su totalidad
el futuro que sus acciones
proyectan?!*

*Y, sin miedo a equivocarme,
ningún humano quiere imaginar
lo que le espera a largo plazo,
porque resulta un trabajo inverosímil.*

*Si el futuro es inefable,
entonces, el tiempo no
existe...*

*Y nuestra vida se mantiene
en un presente continuo.
Pero si deja de serlo
se vuelve tan palpable
como lo que vivo
hoy.*

* * *

Mi lucubración futura...

DEDICATORIA

Al amor de mi vida, mi amada Maestra en Ciencias Carmela Pérez Hernández por motivarme, ayudarme, enseñarme, quererme y ser tan linda conmigo.

A mi madre Ma. Remedios Hernández Castro y a mi padre Javier Medina Pérez, por estar siempre dispuestos a escucharme y apoyarme para encontrar la sapiencia, tranquilidad y ánimos que requería en cada momento, vitales para lograr alcanzar mis objetivos. Son el motivo de mi esfuerzo y mi razón de ser.

A mis hermanos Ma. Azucena Medina Hernández y Yaved Medina Hernández, a mis cuñados Ma. Mónica Zavala Mendoza y Juan Diego Andrade Ramírez y a mis sobrinos Ma. Guadalupe Andrade Medina, Zoe Soledad Andrade Medina, Dulce Carol Medina Zavala y Jesús Yaved Medina Zavala por cada momento de inspiración, consejos y valentía que reforzaron de decisión mis acciones para andar con paso firme y sobrellevar con entereza los momentos difíciles. Sin ustedes no hubiera tenido sentido cada acción que he tomado, por eso, les dedico mi trabajo y esfuerzo.

Las dedicatorias especiales son para mis abuelos maternos Irene Castro Caballero y José Hernández Estrada y mis abuelos paternos Ma. Guadalupe Pérez Vargas y José Socorro Medina Paniagua por ser pilares vitales en mi formación integral, llena de valores, consejos y apoyo incondicional. Los llevaré siempre en mi corazón, a donde quiera que estén y a donde quiera que vayan.

A mi gran amigo German Serra Suarez por sus sabias palabras y cavilaciones que me ayudaron en demasía para luchar con la duda.

A mi esfuerzo, a mi duda, a los bosques, a los niños del futuro... A la vida... por concederme la esencia para observar, hacer, reflexionar y aprender el futuro.

AGRADECIMIENTOS

Con la mano en mi corazón, mi razonamiento firme, una sonrisa cordial, mis pensamientos diáfanos... y un baúl rebotante de recuerdos lúcidos de la Maestría en Ciencias... quiero expresar mis más sinceros y afables agradecimientos a las personas e instituciones que atendieron, apoyaron, contribuyeron y valoraron los objetivos de esta investigación ¡Su ayuda fue imprescindible!... sin ustedes no hubiera sido posible culminar con éxito tan ardua tarea: describir el futuro del sector forestal de México.

Al Dr. Francisco José Zamudio Sánchez por su invaluable y acertada dirección, erudición, confianza y, sobre todo, por el apoyo que me otorgó, a pesar de todos los inconvenientes encontrados. Sin su consideración no podría haber sido posible la realización y finalización de este trabajo de investigación. Mis más sinceros, cordiales e infinitos agradecimientos.

Al Dr. Alejandro Ismael Monterroso Rivas por sus sabios consejos, paciencia, recomendaciones y charlas amenas. Le agradezco mucho por todos sus aportes.

Al Dr. Gabriel Arcángel Rodríguez Yam por su docencia sutil, recomendaciones y por enseñarme a valorar lo importante que es informar de forma sencilla y clara cualquier cosa, aunque parezca difícil. Porque, como dice: "se puede ganar la presidencia en un minuto, ya que en un minuto se dice mucho". Ahora lo creo. Quedo muy agradecido con usted.

A la Dra. Adriana Avalos Vargas por todo su apoyo, acertados consejos, y, sobre todo, por estar presente en esos momentos que más necesitaba de ayuda en la investigación. Su carácter e inteligencia contribuyeron, en gran medida, en la mejora de las actividades de este trabajo y fueron indispensables para llevar a buen término mi objetivo de vida. Con mi mano en el corazón le doy las gracias.

A la Dra. Ma. Amparo Máxima Borja de la Rosa por su docta y equilibrada dirección. Sus consejos, tiempo y apoyo fueron vitales para desarrollar satisfactoriamente cada uno de los requisitos de la Maestría y esta investigación. Quedo muy agradecido con usted.

A la MC. Carmela Pérez Hernández por estar siempre dispuesta en ayudar con las dudas y reflexiones relacionadas con el manejo forestal sostenible, la Gobernanza Ambiental y la Economía de los Recursos Naturales. Todos los aportes me movieron cada día para lograr alcanzar mi objetivo y no desistir en el intento. Mi corazón agradece todo tu apoyo, ánimos y compañía.

A mis maestros que me impartieron sus conocimientos y habilidades durante los cursos y asesorías que me fueron de gran utilidad para consolidar un aprendizaje integral e interdisciplinario. En especial agradezco a la Dra. Luz Judith Rodríguez Esparza, al Dr. Asael Fabian Martínez Martínez y al Dr. Rolando Israel Valdez Ramírez que fueron Cátedra CONACyT durante mis estudios en la Maestría en Ciencias. Sus habilidades en Matemáticas, Estadística, Computación y Economía mejoraron mi visión y comprensión de estas áreas del conocimiento vastas y complejas. Les agradezco mucho por todas las asesorías y aprendizajes vividos.

A la secretaria Luz Magali Moreno Rodríguez por coordinar, colaborar y apoyar en cada proceso de trámites durante mi estancia en la Maestría. Le agradezco por todo su tiempo, consejos y sinceros aportes para finalizar mis cursos e investigación.

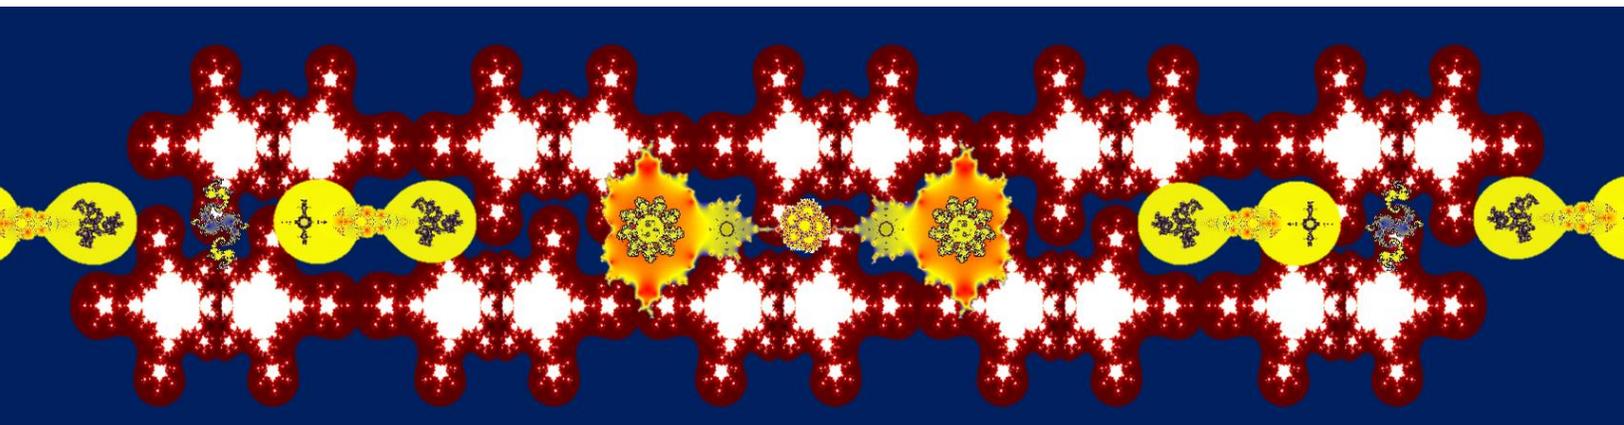
A mis compañeros Diana Laura Torres, Nazly Abadi Mejorado, Alfredo Méndez, Luis Romahn y Omar Camacho les agradezco mucho por cada momento lleno de conocimiento, investigación y júbilo, ya que, con ustedes, se hizo amena y provechosa mi estancia en la Maestría en Ciencias Forestales.

A mis familiares, amigos, compañeros y conocidos que estuvieron en cada momento, apoyando y aportando consejos vitales para lograr alcanzar cada objetivo que me he propuesto en mis estudios de Posgrado. Les agradezco sinceramente.

Al Consejo Nacional de Ciencia y Tecnología por ser la institución que financió mis estudios de posgrado, les agradezco sinceramente la oportunidad que me proporcionaron y que no desaproveché nunca. Cada día, semana y mes financiado se reflejan en mis calificaciones oficiales satisfactorias y en ésta, mi investigación final.

A la Universidad Autónoma Chapingo (UACH), principalmente al Departamento de Ciencias Forestales por brindarme todas las facilidades para hacer uso de sus increíbles instalaciones y servicios básicos indispensables que sirvieron para culminar esta investigación y para obtener estudios de posgrado de alta calidad y reconocimiento nacional e internacional. Me voy siendo chapinguero, con una educación, cultura, ética y valores que nunca olvidaré... por eso y más, quedo agradecido por la eternidad con tan noble Universidad.

¡Por siempre gracias... UACH!



DATOS BIOGRÁFICOS

Datos personales

Nombre: Javier Medina Hernández

Fecha de nacimiento: 28 de octubre de 1989

Lugar de nacimiento: Morelia, Michoacán

No. Cartilla militar: 9960109

CURP: MEHJ891028HMNDRV05

Profesión: Ingeniero Agrónomo Especialista en Fitotecnia

Cédula profesional: 11225680



Desarrollo académico

Originario de Morelia, Michoacán, México, desarrolló sus estudios de Licenciatura en el Departamento de Enseñanza e Investigación en Fitotecnia de la Universidad Autónoma Chapingo, en el Estado de México, obteniendo el título de Ingeniero Agrónomo Especialista en Fitotecnia en noviembre de 2017, con la tesis titulada: “Prospectiva del sector agropecuario de México para el 2050 con el uso de redes neuronales artificiales”.

En la primavera de 2018 ingresó al Programa de Posgrado en Ciencias Forestales, en la División de Ciencias Forestales de la Universidad Autónoma Chapingo, en donde concluyó sus estudios de Maestría en Ciencias en Ciencias Forestales en el 2019.

RESUMEN GENERAL

PROYECCIONES HASTA EL AÑO 2100 DE VARIABLES CLAVE EN EL SECTOR FORESTAL DE MÉXICO Y SU ANÁLISIS EN LA POLÍTICA PÚBLICA¹

La creciente degradación y pérdida actual de los bosques de México y el mundo, ocasionadas principalmente por las actividades antropogénicas, plagas, especies no nativas y cambio climático, se han convertido en temas que son cada vez más relevantes para la comunidad internacional, debido a las consecuencias que ocasionan: eventos climáticos extremos, agotamiento de los recursos forestales, pérdida de biodiversidad, contaminación ambiental y la disminución en la calidad y cantidad de agua. En este contexto, el objetivo fue proyectar hasta el año 2100 las variables clave del sector forestal de México: producción, importación y exportación forestal maderable y la superficie forestal arbolada. Se realizó una revisión de literatura, para describir la situación actual y seleccionar las variables de estudio. Se descargaron los datos anuales de las bases de datos oficiales y se elaboraron las series de tiempo. Las proyecciones al 2100 se estimaron con el uso de redes neuronales recurrentes del tipo “Long Short-Term Memory” (LSTM) de aprendizaje profundo. Éstas aportaron un error bajo, después de un entrenamiento previo a cada una de las proyecciones anuales obtenidas. Con el análisis de las proyecciones se obtuvo que el crecimiento y necesidades de la población de México y el mundo seguirán afectando las más de 137 millones de hectáreas (ha) de superficie forestal hasta el año 2100, de continuar con las tendencias actuales: el 31 % de los bosques mexicanos presentan vegetación modificada o alterada y la producción ilegal de madera cubre más de la mitad de la demanda nacional. Se estima que para el año 2100 la superficie forestal arbolada (66 millones de ha) disminuya cerca de 6 millones de ha, la producción maderable se mantendrá en un promedio de 44 millones de m³ y se exportará e importará entre 40-50 y 25-50 mil m³, respectivamente. Se concluye que, si continua la degradación forestal en México se requerirá de evaluar, crear e implementar políticas públicas y planes de manejo sostenibles, enfocados a cada región, para satisfacer las necesidades presentes y futuras de la sociedad.

Palabras clave: superficie forestal arbolada, producción, importación y exportación forestal maderable; redes neuronales recurrentes-LSTM; aprendizaje profundo; manejo forestal sostenible; toma de decisiones.

¹Tesis de Maestría en Ciencias, Universidad Autónoma Chapingo
Autor: Javier Medina Hernández
Director de Tesis: Dr. Francisco José Zamudio Sánchez

GENERAL ABSTRACT

PROJECTIONS UNTIL THE YEAR 2100 OF KEY VARIABLES IN THE FOREST SECTOR OF MEXICO AND THEIR ANALYSIS IN PUBLIC POLICY²

The current increasing degradation and loss of forests in Mexico and the world, caused mainly by anthropogenic activities, pests, non-native species and climate change, have become issues that are increasingly relevant to the international community, due to the consequences that cause: extreme climate events, depletion of forest resources, loss of biodiversity, environmental pollution and the decrease in the quality and quantity of water. In this context, the objective was to project until the year 2100 the key variables of the forest sector in Mexico: production, import and export of timber forest and wooded forest area. A literature review was performed to describe the current situation and select the study variables. Annual data was downloaded from official databases and time series were prepared. The projections to 2100 were estimated with the use of recurrent neural networks of the type "Long Short-Term Memory" (LSTM) of deep learning. These provided low error, after training prior to each of the annual projections obtained. With the analysis of the projections, it was obtained that the growth and needs of the population of Mexico and the world will continue to affect the more than 137 million hectares (ha) of forest area until the year 2100, to continue with current trends: the 31 % of Mexican forests have modified or altered vegetation and illegal wood production covers more than half of national demand. It is estimated that by the year 2100 the wooded forest area (66 million ha) will decrease about 6 million ha, timber production will remain at an average of 44 million m³ and will be exported and imported between 40-50 and 25- 50 thousand m³, respectively. It is concluded that, if forest degradation continues in Mexico, it will be necessary to evaluate, create and implement sustainable public policies and management plans, focused on each region, to satisfy the present and future needs of society.

Palabras clave: wooded forest area, timber forest production, import and export; recurrent neural networks-LSTM; Deep Learning; sustainable forest management; decision making.

²Thesis, Universidad Autónoma Chapingo
Author: Javier Medina Hernández
Advisor: Dr. Francisco José Zamudio Sánchez

1 INTRODUCCIÓN GENERAL

Los bosques de todo el mundo son vitales para la seguridad alimentaria y para mejorar los medios de subsistencia, debido a que proporcionan alimentos, agua, aire, forraje, fibras, dendroenergía y refugio; además albergan la biodiversidad, regulan el clima, retienen el suelo, mantienen la sostenibilidad de la agricultura y ganadería, generan ingresos y empleo para el bienestar humano (Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO], 2016).

Por lo que se requiere de planes de manejo sostenibles (MFS), tanto en México como en el mundo, para proteger los recursos forestales, de tal forma que se satisfagan las necesidades de la sociedad actual y se conserven los bosques necesarios para las generaciones futuras (FAO, 2019a; Fraser, 2019). Para ello, se debe de elaborar políticas públicas (Santana et al., 2020) enfocadas a resolver cada uno de los problemas actuales que se presentan en la mayoría de los bosques del mundo, de los que destacan: deforestación, degradación, cambio de uso de suelo, incendios, energía, eventos climáticos extremos, plantas invasoras, pérdida de biodiversidad, plagas y enfermedades (Bonilla-Moheno & Aide, 2020; Brinkmann, 2020; Creutzig, 2019; Ferreira, 2020; Monjarás-Vega et al., 2020).

Se estima que esta problemática se agrave hasta el año 2100, dado que el sector forestal mexicano se modifica por: el crecimiento rápido y constante de la población (Organización de las Naciones Unidas [ONU], 2019); el aumento en el número de personas en situación de pobreza (Consejo Nacional de Evaluación de la Política de Desarrollo Social [CONEVAL], 2019) e inseguridad alimentaria (FAO, 2019b); las políticas públicas que benefician al mercado mundial, que ve a este sector y al agropecuario como un gran negocio (Soria & Palacio, 2014); y por la nueva recesión económica mundial provocada por la pandemia del COVID-19 (Ali & Alharbi, 2020; Goodell, 2020; Huang et al., 2020), que a la fecha ha causado la muerte de más de un tercio de millón de personas (Organización Mundial de la Salud [OMS], 2020) y una pérdida millonaria en muchos sectores (Bloomberg Economics, 2020).

En este contexto, el objetivo del presente es proyectar hasta el año 2100 las variables clave en el sector forestal de México, a partir de series de tiempo y redes neuronales recurrentes (recurrent neural network-RNN) de aprendizaje profundo, para explicar las consecuencias de las actividades antropogénicas en los bosques mexicanos y orientar el presente.

Dado que, el futuro no está escrito, entonces es posible encontrar el patrón presente en los datos que dependen del tiempo. Por lo cual, en la actualidad, se usan las RNN para obtener proyecciones, en especial las de tipo “Long Short-Term Memory” (RNN-LSTM), que son una variante con un rendimiento superior y producen un error bajo (Bianchi et al., 2017; Graves, 2012; Hochreiter & Schmidhuber, 1997; Schmidhuber, 2015). Además, se requieren datos a largo plazo, más allá de los altibajos del corto plazo que son típicos de los ciclos económicos y políticos (PwC UK, 2017) y de los beneficios privados inmediatos (Merino, 2019), para que se observen las consecuencias de la problemática planteada en las variables seleccionadas: producción, importación y exportación forestal maderable y la superficie arbolada de México.

Finalmente, el presente documento está compuesto por cinco capítulos: el primer capítulo contiene la introducción general con la descripción del planteamiento del problema, la justificación y los objetivos; el capítulo dos integra el marco teórico; en el capítulo tres se presenta el artículo: Proyecciones hasta el año 2100 de variables clave en el sector forestal de México; en el capítulo cuatro se establece el artículo dos: Análisis de los datos del sector forestal de México y el mundo; y en el capítulo cinco se exponen las conclusiones generales.

1.1 Objetivos

1.1.1 Objetivo general:

Proyectar las tendencias de las variables clave del sector forestal de México hasta el año 2100, a partir de bases de datos históricas y RNN-LSTM de aprendizaje profundo para mostrar el posible futuro de continuar con las

tendencias actuales en el sector forestal y que sirvan como base para denotar las consecuencias de las actividades antropogénicas y orientar la toma de decisiones en el presente.

1.1.2 Objetivos particulares:

- Diseñar la arquitectura de las RNN-LSTM con el uso de paqueterías en Python para realizar las proyecciones de las variables clave.
- Elaborar las proyecciones al 2100 de la producción, importación y exportación forestal maderable y la superficie arbolada de México, con las series de tiempo y las RNN-LSTM, para mostrar el posible futuro de continuar con las tendencias actuales en el sector forestal.
- Realizar un estudio de la situación pasada y presente del sector forestal de México y el mundo, con una revisión de literatura, para entender las causas de las proyecciones a largo plazo.
- Analizar el panorama de las proyecciones, a partir del estudio del pasado y presente del sector forestal, para describir las principales consecuencias de las actividades antropogénicas.
- Proponer alternativas de conservación del sector forestal de México, analizando la información obtenida del estudio del pasado y las proyecciones, para orientar la toma de decisiones.

1.2 Literatura citada

Ali, I., & Alharbi, O. M. (2020). COVID-19: Disease, management, treatment, and social impact. *Science of The Total Environment*, 728, 138861. <https://doi.org/10.1016/j.scitotenv.2020.138861>

Bianchi, F. M., Maiorino, E., Kampffmeyer, M. C., Rizzi, A., & Jenssen, R. (2017). *Recurrent neural networks for short-term load forecasting: an overview and comparative analysis*. Edit. Springer Nature. Cham, Switzerland. <https://doi.org/10.1007/978-3-319-70338-1>

- Bloomberg Economics. (2020). Global \$6 trillion slump may be optimistic, economists warn. Recuperado el 1 de mayo del 2020, de <https://www.bloomberg.com/news/articles/2020-04-27/global-6-trillion-slump-may-be-optimistic-bloomberg-economics>
- Bonilla-Moheno, M., & Aide, T. M. (2020). Beyond deforestation: Land cover transitions in Mexico. *Agricultural Systems*, 178, 102734. <https://doi.org/10.1016/j.agsy.2019.102734>
- Brinkmann, R. (2020). Interconnections in Environmental Sustainability: Water and Energy. In R. Brinkmann (Ed.), *Environmental Sustainability in a Time of Change* (pp. 195-216). Cham, Switzerland: Palgrave Macmillan. https://doi.org/10.1007/978-3-030-28203-5_9
- Merino P., L. (2019), *Crisis ambiental en México: ruta para el cambio*. UNAM. México. https://observatorio.susmai.unam.mx/wp-content/uploads/2019/AgendaAmbiental_RED.pdf#page=165
- Consejo Nacional de Evaluación de la Política de Desarrollo Social. (2019). Diez años de medición de pobreza multidimensional en México: avances y desafíos en política social [pdf]. Recuperado el 8 de abril del 2020, de https://www.coneval.org.mx/Medicion/MP/Documents/Pobreza_18/Pobreza_2018_CONEVAL.pdf
- Creutzig, F., d'Amour, C. B., Weddige, U., Fuss, S., Beringer, T., Gläser, A., ... & Edenhofer, O. (2019). Assessing human and environmental pressures of global land-use change 2000–2010. *Global Sustainability*, 2, artículo 1. <https://doi.org/10.1017/sus.2018.15>
- Ferreira, L. N., Vega-Oliveros, D. A., Zhao, L., Cardoso, M. F., & Macau, E. E. (2020). Global Fire Season Severity Analysis and Forecasting. *Computers & Geosciences*, 134, artículo 104339. <https://doi.org/10.1016/j.cageo.2019.104339>
- Fraser, A. (2019). *Achieving the Sustainable Management of Forests*. Cham, Switzerland: Springer International Publishing. <https://doi.org/10.1007/978-3-030-15839-2>
- Goodell, J. W. (2020). COVID-19 and finance: Agendas for future research. *Finance Research Letters*, artículo 101512. Prepublicación online. <https://doi.org/10.1016/j.frl.2020.101512>
- Graves, A. (2012). *Supervised sequence labelling*. In Supervised sequence labelling with recurrent neural networks (pp. 5-13). Springer, Berlin, Heidelberg. <https://doi.org/10.1007/978-3-642-24797-2>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Huang, C., Wang, Y., Li, X., Ren, L., Zhao, J., Hu, Y., ... & Cheng, Z. (2020). Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. *The lancet*, 395(10223), 497-506. [https://doi.org/10.1016/S0140-6736\(20\)30183-5](https://doi.org/10.1016/S0140-6736(20)30183-5)

- Monjarás-Vega, N. A., Briones-Herrera, C. I., Vega-Nieva, D. J., Calleros-Flores, E., Corral-Rivas, J. J., López-Serrano, P. M., ... & Alvarado-Celestino, E. (2020). Predicting forest fire kernel density at multiple scales with geographically weighted regression in Mexico. *Science of The Total Environment*, 718, artículo 137313. <https://doi.org/10.1016/j.scitotenv.2020.137313>
- Organización de las Naciones Unidas. (2019). World Population Prospects 2019. Recuperado el 15 de abril del 2020, de <https://population.un.org/wpp/DataQuery/>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2016). Evaluación de los recursos forestales mundiales 2015: ¿Cómo están cambiando los bosques del mundo? (Segunda ed.). <http://www.fao.org/3/a-i4793s.pdf>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2019a). *Sustainable forest management*. Recuperado el 28 de noviembre de 2019, de <http://www.fao.org/forestry/sfm/en/>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura (2019b). El estado de la seguridad alimentaria y la nutrición en el mundo 2019: Protegerse frente a la desaceleración y el debilitamiento de la economía [pdf]. En colaboración con: OMS y UNICEF. Roma. Recuperado el 28 de abril del 2020, de <http://www.fao.org/3/ca5162es/ca5162es.pdf>
- Organización Mundial de la Salud. (2020). Coronavirus disease (COVID-19): Situation Report-126 [pdf]. Recuperado el 25 de mayo del 2020, de https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200525-covid-19-sitrep-126.pdf?sfvrsn=887dbd66_2
- PwC UK. (2017). Una mirada al futuro: ¿Cómo cambiará el orden económico mundial para el 2050? [pdf]. Recuperado el 8 de abril del 2020, de https://www.pwc.com/co/es/assets/document/el_mundo_en_2050.pdf
- Santana, J. R. H., Manent, M. B., Linares, A. P. M., Delhumeau, E. O., Zorrilla, M., & Hernández, A. O. (2020). Aptitud sectorial para el desarrollo forestal: consideraciones en la ordenación general del territorio mexicano. *Cuadernos geográficos de la Universidad de Granada*, 59(1), 32-53. <https://doi.org/10.30827/cuadgeo.v59i1.8079>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Soria S., G. & Palacio M., V. H. (2014). El escenario actual de la alimentación en México. *Textos & Contextos (Porto Alegre)*, 13(1), 128-142. <https://doi.org/10.15448/1677-9509.2014.1.16223>

2 REVISIÓN DE LITERATURA

2.1 Sector forestal

2.1.1 Situación mundial

A nivel mundial, se estimó el área forestal global en 4,060 millones de ha, es decir cerca de un tercio de la superficie de tierra en el mundo es destinada a los bosques, de la cual el 54 % lo ocupan: Rusia, Brasil, Canadá, Estados Unidos de América (EUA) y China, con 815, 497, 347, 310 y 220 millones de ha para cada caso. En cuanto a la producción, se calcula que cerca del 30 % del total de bosque se utiliza para la obtención de madera y productos no madereros (1,150 millones de ha). Además, la superficie mundial dedicada a la conservación de la biodiversidad se midió en 424 millones de ha y para la protección del suelo y el agua se estimó en 399 millones de ha, por lo que se observó una disminución de 100 millones de ha destinadas a la conservación del 2015 a 2020 (FAO, 2020).

Por lo tanto, es necesario implementar MFS, los cuales requieren a su vez de anticipar el futuro, para desarrollar políticas ambientales enfocadas en una gestión y protección de estos sistemas complejos. De ahí que en el mundo ha aumentado la preocupación por analizar la situación pasada, presente y futura de los bosques. Varios países destacan por realizar trabajos referidos a obtener estudios amplios sobre las fuerzas que están remodelando los bosques, EUA es un ejemplo (Wear & Greis, 2012, 2013). Pero, no todos los países hacen este tipo de trabajos, debido a la dificultad, a la cantidad de investigadores requeridos y al alto costo, tanto en dinero como en tiempo, para desarrollar perspectivas de las variables clave del sector forestal.

Los factores siguientes son en los que se centran los objetivos de dichos estudios: cambios en los usos del suelo (principalmente para la agricultura, ganadería, transporte y zonas urbanas), problemas biológicos (enfermedades y plagas, principalmente de insectos), problemas abióticos (cambio climático, disponibilidad y calidad del agua, captura de carbono, concentración de nitrógeno

en el suelo, incendios), cuestiones socioeconómicas (políticas ambientales, aumento de la población, cambios en la propiedad forestal, sistemas de producción, aumento en la demanda, mercados de madera, incendios, tecnología y precios de los biocombustibles), comunidades de vida silvestre (biodiversidad) y especies invasoras (Bonilla-Moheno & Aide, 2020; Creutzig, 2019; Ferreira, 2020; Monjarás-Vega et al., 2020; Wear & Greis, 2012, 2013).

Por otro lado, para desarrollar el sector forestal, se requiere que el crecimiento anual neto del bosque en la tierra disponible para la cosecha periódica sea más que el doble de extracciones (para que se logre tener un inventario de madera en pie en aumento) y modernizar la industria encargada de transformar la madera que se cosecha, en productos terminados, sin tener desperdicios. Esto beneficiará a la industria, ya que se estima altamente eficiente y diversa (Bowyer, 2016). Pero el verdadero desafío será el conservar las áreas forestales con un MFS y satisfacer la demanda creciente, debido a que se prevé que, con el aumento de la población (Figura 1) (Organización de las Naciones Unidas [ONU], 2019), continúe creciendo la urbanización, la agricultura y la ganadería extensiva.

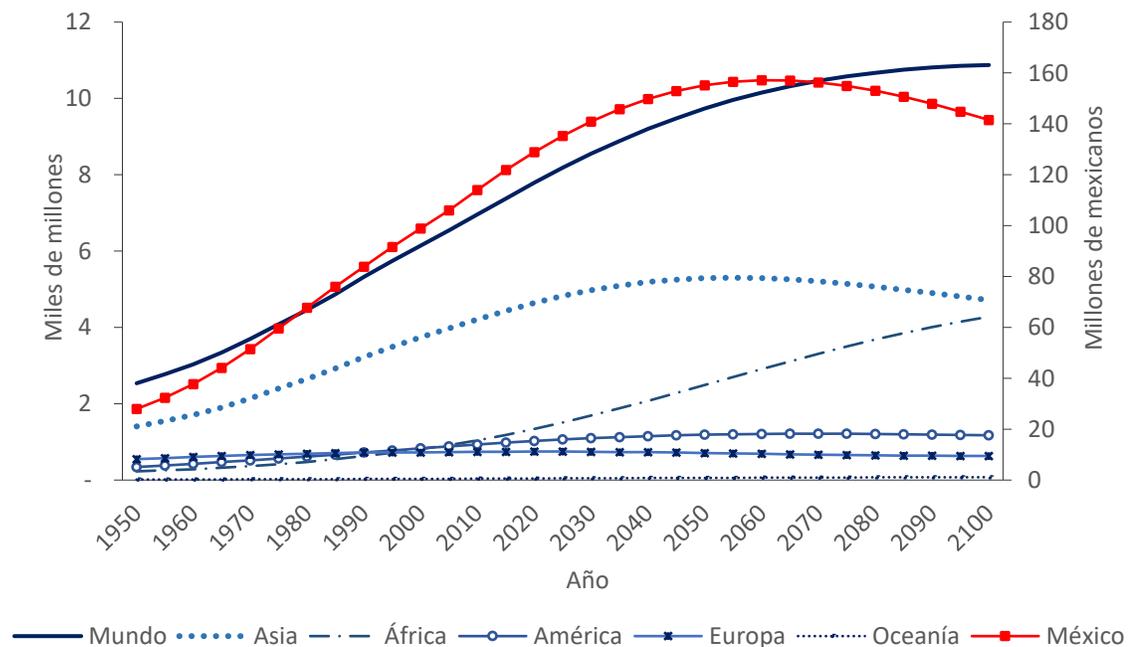


Figura 1. Crecimiento de la población del mundo y los continentes en el periodo 1950-2100. Fuente: Elaboración propia con datos de la ONU, 2019.

Se requiere de estudios avanzados, donde se utilice el Big Data, para encontrar y describir los problemas más importantes que destruyen los bosques (Potter et al., 2019). La gran cantidad de datos de monitoreo disponibles en la actualidad (prácticas de gestión, distribución de plantaciones, condiciones ambientales y mapas de vegetación), ha mejorado enormemente nuestra comprensión de los impactos de las prácticas de manejo y plantación forestal en los servicios ecológicos y socioeconómicos, a escala local nacional, regional y mundial (Chen et al., 2017).

2.1.2 Los bosques de México: pasado, presente y futuro

El pasado del sector forestal de México

Desde los tiempos de la Colonia, la Independencia y la Revolución Mexicana se ha vivido en una depredación ambiental sin precedentes que involucra, primero a la explotación minera, la extracción de maderas preciosas y después a las concesiones de tierras y al desarrollo de la industria agroalimentaria. Donde la supuesta modernidad de la Revolución Verde y otros programas privó de los recursos naturales a los pueblos indígenas de México, que habían sabido cuidar satisfactoriamente sus recursos naturales durante siglos (Merino, 2019).

Con la Comisión Nacional de Desmontes se sentó las bases legales para aumentar la destrucción de los bosques. Posteriormente no se vieron grandes cambios a pesar de las nuevas instituciones que tenían el objetivo de proteger los bosques, como la Secretaría de Medio Ambiente. Aunado a lo anterior, se han registrado eventos climáticos extremos, resultado del cambio climático, que afecta a la naturaleza y a las personas más vulnerables. Por otro lado, en el gobierno se toman las decisiones priorizando, en primer lugar, un desarrollo económico por encima de la pérdida de capital natural (Merino, 2019).

En resumen, la situación socioeconómica y ambiental de México es un proceso histórico de acontecimientos, políticas económicas, reformas y decisiones sociales (Calva & Macías, 2007; Uribe, 2014).

Situación actual de los bosques de México

México se caracteriza por contar actualmente con un territorio de 196 millones de hectáreas, 138 millones de ha son designadas como superficie forestal, es decir, el 71 % del territorio nacional. Esta superficie forestal se organiza en ecosistemas y, éstos, en 11 formaciones forestales (54 tipos de vegetación); por lo tanto, los ecosistemas que ocupan una mayor superficie del área forestal son: el matorral xerófilo (zonas áridas: 26.1 % y semiáridas: 14.7 %), los bosques (coníferas y latifoliadas: 9.4 %, latifoliadas: 8.2 %, coníferas: 5.9 % y bosque mesófilo de montaña: 1.3 %), selvas (selvas bajas: 11.9 % y selvas altas y medianas: 9.8 %), otras áreas forestales no arboladas (11.5 %), manglares (0.7 %) y otras asociaciones arboladas (0.4 %) (Comisión Nacional Forestal [CONAFOR], 2018).

Además, se considera que aproximadamente un tercio del área forestal está siendo modificada o alterada (vegetación secundaria); las selvas altas-medianas, selvas bajas, bosque de latifoliadas y bosque de coníferas-latifoliadas son las que presentan una mayor superficie con daños, con cerca de 10.3, 9.5, 4.9 y 4.8 millones de ha respectivamente, juntos suman el 68 % del área de vegetación secundaria (CONAFOR, 2018). Este cambio y modificación constantes y rápidos son resultado de lo descrito en el pasado del sector forestal y también por el crecimiento y necesidades de la población mexicana, la pérdida de la soberanía alimentaria de México (causada por el mercado mundial y el sistema económico neoliberal, en donde la alimentación representa un gran negocio; Soria & Palacio, 2014) y porque el sector forestal y agropecuario han sido desplazados como palancas de desarrollo del país, primero por la exportación de petróleo y después por el sector exportador de manufacturas (Pérez, 2013).

El impacto social actual, de esta crisis forestal y agropecuaria se agrava cuando estos sectores no son capaces de crear empleo y, además, por la economía global competitiva y de alta tecnología se está expulsando de su trabajo a los pequeños productores, campesinos y agricultores (Appendini & Torres-Mazuera, 2008; Vargas, 2000). Como resultado, cerca del 42 % de los mexicanos se encuentra en situación de pobreza, población que se encuentra, principalmente,

en las zonas rurales (Consejo Nacional de Evaluación de la Política de Desarrollo Social [CONEVAL], 2019).

Sin bosques y sin agua en calidad y cantidad, se ve acrecentada la migración, los índices de violencia, la deforestación y degradación ilegal de los recursos naturales (Merino, 2019).

Perspectivas del sector forestal mexicano

El futuro de las áreas de plantación y distribución forestal estarán determinadas por muchos factores, incluidos los siguientes: aumento en la demanda de productos de madera; la necesidad de producir más alimentos y fibras; nuevas tecnologías; mercado y precios de la bioenergía; cambio climático; políticas ambientales; y otros factores socioeconómicos (FAO, 2009; Wear & Greis, 2012).

Además, se estima que siga en aumento la superficie de bosque plantado tanto en México como en el mundo (FAO, 2020). Por lo que, desde una perspectiva socioeconómica, los bosques plantados generarán ganancias económicas positivas junto con la prestación de servicios ambientales; desde la perspectiva del crédito de carbono, estos bosques son considerados como un contribuyente importante al sumidero de carbono (Chen et al., 2017). Aunque, son la causa de futuros problemas con la pérdida de biodiversidad por emplear plantas exóticas (Newbold et al., 2015). Situación que debe considerarse en el largo plazo.

Por lo tanto, las investigaciones realizadas sobre el futuro del sector forestal sirven para entender la dinámica del carbono, nitrógeno y agua, lo cual puede mitigar los efectos del cambio climático al considerar dichos flujos. Además, si se emplea un manejo eficiente, sostenible y adaptado a todos los bosques de México se determinará el éxito de la conservación de los bosques; y con un sector estable, robusto y rentable se beneficiará a los productores porque aumentarán las ganancias económicas y mejorará la prestación de los servicios ambientales (Bowyer, 2016; Chen et al., 2017). Como ejemplo de países desarrollados que

han implementado un MFS y han obtenido dichos beneficios se encuentran: EU, Canadá, Rusia y China (Bowyer, 2016; Chen et al., 2017; FAO, 2016, 2020).

Finalmente, desde el punto de vista de las políticas públicas y la gobernanza ambiental se requiere de tomar en cuenta que lo anterior será factible si se sacrifican varios beneficios individuales inmediatos para obtener beneficios públicos en el largo plazo, por lo que no habrá un futuro favorable sin un MFS y un respeto por las personas que cuidan de todos los recursos naturales. Por tanto, proteger nuestros bosques, selvas, ríos, lagos, mares, es un trabajo que requiere México de manera urgente (Merino, 2019).

2.2 Series de tiempo

2.2.1 Características generales

En la mayoría de las áreas del conocimiento existen diversos fenómenos que pueden ser medidos y representados como series de tiempo, los cuales van desde los fenómenos naturales, como la temperatura (Figura 2) o las precipitaciones, hasta variables económicas, como la producción industrial o las cuotas diarias del mercado de valores. Los estudios relacionados con las series de tiempo son considerables por dos motivos principales, el primero porque son una herramienta para el análisis estadístico de datos periódicos y el segundo por la posibilidad de obtener proyecciones que son de importancia para la sociedad en general (Rojas & Pomares, 2016).

Bajo este enfoque, Shumway y Stoffer (2017) definen a las series de tiempo como: “un conjunto de observaciones Z_t , cada una de las cuales se registra en un tiempo específico t ”. Una serie de tiempo pueden ser discreta o continua, en el caso discreto las observaciones se registran en intervalos de tiempo fijos (t_0): cada hora, día, mes, año, etc.; por el contrario, las series de tiempo continuas los datos se realizan de forma sucesiva durante un intervalo de tiempo ($t_0 = [0, 1]$). Las series de tiempo discretas son las que, en general, se utilizan para analizar las variables, parámetros o fenómenos de estudio.

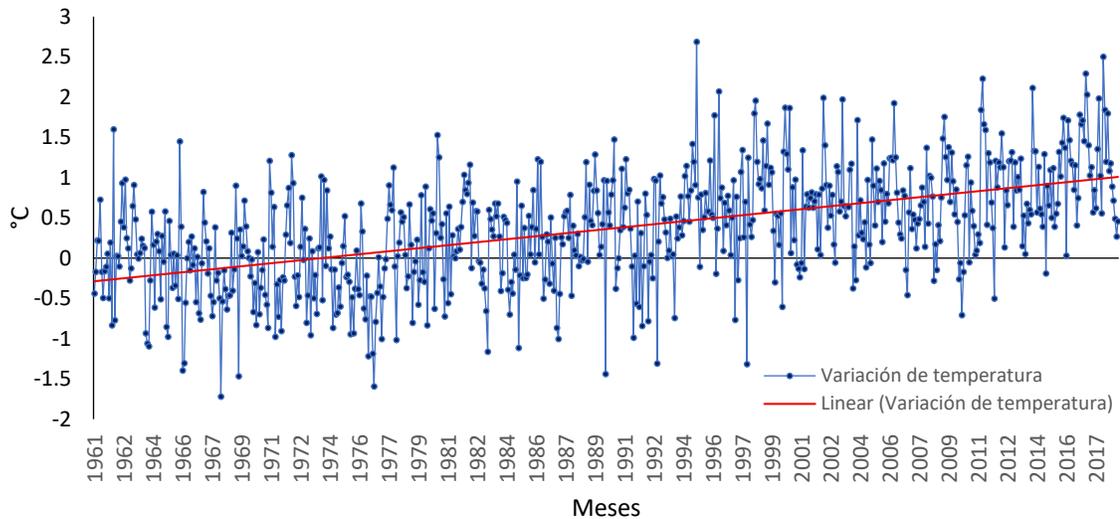


Figura 2. Ejemplo de serie de tiempo: Variación de la temperatura media mensual de México en el periodo: 1961 a 2018. En esta serie con estacionalidad y tendencia se observa que los datos proporcionan información sobre anomalías en la temperatura con respecto al periodo de referencia (1951-1980), la tendencia calculada tiende a ser positiva y se midió un aumento de un grado centígrado para el último lustro. Fuente: Elaboración propia con datos de FAOSTAT, 2019.

2.2.2 Tipos de series de tiempo

Las series de tiempo también pueden ser clasificadas por tipos de variación, lo cual se puede apreciar al observar el diagrama de tiempo o gráfico. A continuación, se describen las variaciones más representativas descritas por Chatfield y Xing (2019):

- **Variación estacional:** las series de tiempo que presentan esta característica tienen una media, varianza y función de autocorrelación constantes a lo largo del tiempo, es decir, las propiedades de una sección de la serie son muy similares a las de cualquier otra sección. Algunos ejemplos figuran en: las precipitaciones (Figura 3), ventas o desempleo que, generalmente, aumentan en verano y disminuyen en invierno.

En este tipo de variación se distinguen dos variantes de estacionalidad: la aditiva y la multiplicativa. Las variaciones se representan en los tres modelos siguientes:

$$Z_t = m_t + S_t + \varepsilon_t, \tag{1}$$

$$Z_t = m_t \cdot S_t + \varepsilon_t, \quad (2)$$

$$Z_t = m_t \cdot S_t \cdot \varepsilon_t, \quad (3)$$

donde: m_t es el nivel medio desestacionalizado en el tiempo t , S_t es el efecto estacional en el tiempo t , y ε_t es el error aleatorio. En la ecuación 1 se representa el caso aditivo de una serie de tiempo estacional y en las ecuaciones 2 y 3 los modelos multiplicativos. En muchos casos el componente estacional S_t cambia lentamente con el tiempo, por lo que $S_t \approx S_{t-s}$, donde s es el número de observaciones por año.

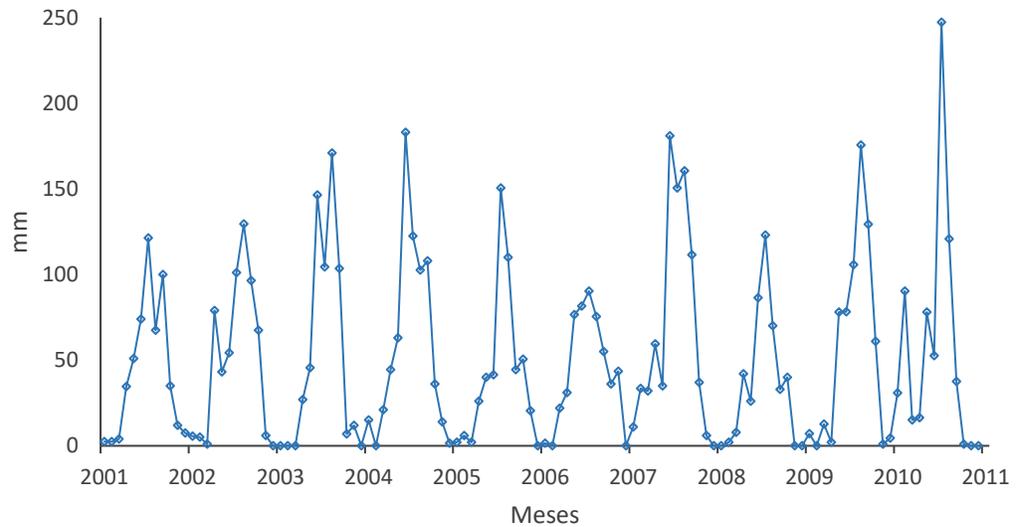


Figura 3. Precipitación total mensual de Chapingo, Texcoco, Edo. Méx. México. Las lluvias en general tienen una variación que hace similar a las mediciones de un año con otro. Fuente: Elaboración propia con datos de la Comisión Nacional del Agua (CONAGUA), 2020.

- **Variación cíclica:** en este tipo de series de tiempo se observan oscilaciones recurrentes entre periodos fijos, generados por alguna causa propia del fenómeno de estudio, que por lo general son eventos que ocurren en fenómenos con ciclos mayores a un año.

Dichos cambios regulares en los valores de la serie de tiempo cubren un periodo más largo en contraste con las series de tiempo con estacionalidad. Las series económicas o la temperatura (Figura 4) son ejemplos de este tipo de variación.

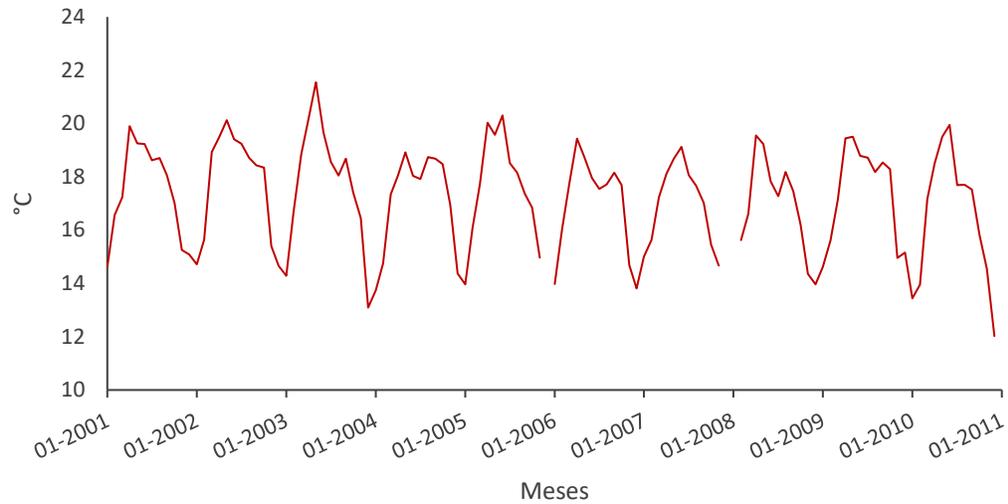


Figura 4. Temperaturas medias mensuales de Chapingo, Texcoco, Edo. Méx. México. Las temperaturas en general son cíclicas, por lo que presentan similitud entre los periodos. Fuente: Elaboración propia con datos de la CONAGUA, 2020.

- **Tendencia:** las series con tendencia son aquellas que presentan un cambio al largo plazo con respecto al nivel medio de los valores de la serie, este cambio puede ser creciente-positivo o decreciente-negativo (Figura 5). La tendencia lineal global de una serie de tiempo se representa como:

$$Z_t = \alpha + \beta t + \varepsilon_t, \quad (4)$$

donde: α y β son constantes y ε_t denota un término de error aleatorio con media cero. El nivel medio viene dado por $mt = (\alpha + \beta t)$. También puede interpretarse la pendiente β como la tendencia, por lo que la tendencia es el cambio en el nivel medio por unidad de tiempo.

En otros casos la tendencia puede ser no lineal y se represente mejor con un crecimiento cuadrático, exponencial u otro polinomio, incluso es posible que los datos son estacionales, como en el primer caso de variación. Los enfoques utilizados para describir la tendencia son: el ajuste de curvas, filtro lineal, diferenciación y otros. Los ejemplos más comunes que muestran una clara tendencia son: la esperanza de vida al nacer, el PIB o el crecimiento de la población.

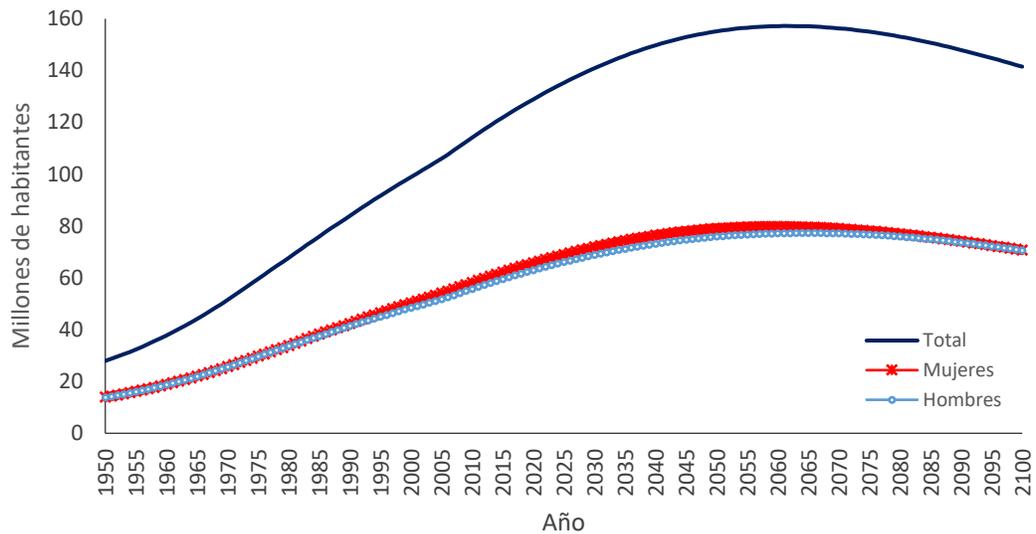


Figura 5. Población de México total y por sexo de 1950 al 2100. La serie de tiempo está elaborada con datos reales en el periodo 1950-2018 y proyecciones hasta el año 2100, además, se observa una tendencia positiva hasta el año 2050 y posterior a este máximo disminuye. Fuente: Elaboración propia con datos de la ONU, 2019.

- **Otras variaciones irregulares:** se presenta en aquellas series de tiempo que no tienen tendencia, ciclos o estacionalidad. Muchas series de tiempo financieras y económicas (Figura 6) presentan esta condición.

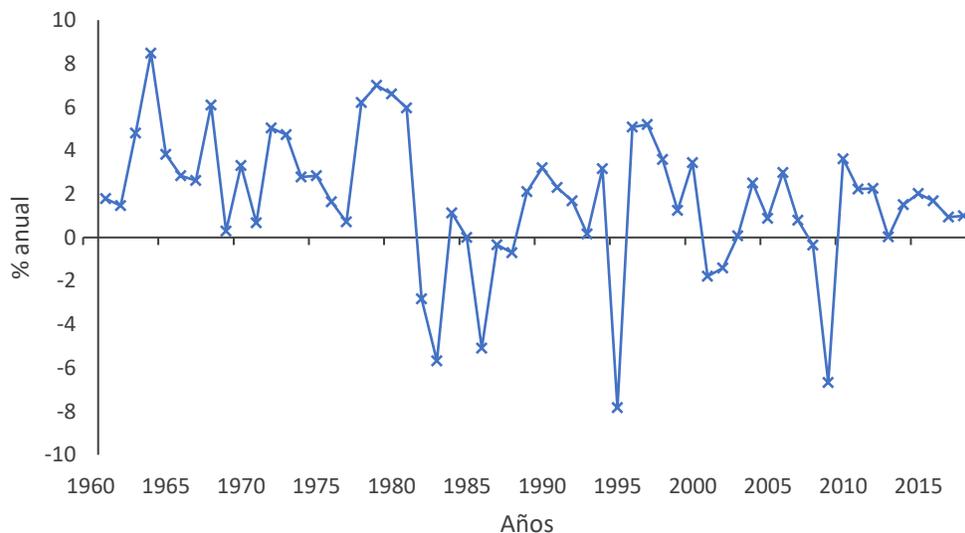


Figura 6. Crecimiento del PIP per cápita de México. En muchas series de tiempo que se generan de variables de estudio en Economía son de este tipo. Fuente: Elaboración propia con datos del Banco Mundial, 2019.

2.2.3 Análisis univariado de series de tiempo

En la actualidad, para el análisis de series de tiempo, se han generado diversos métodos estadísticos que permiten interpretar los valores que describen al fenómeno de estudio, centrando la atención en la dependencia que existe entre las observaciones. Esta característica intrínseca de las series de tiempo da a conocer que las observaciones posteriores son dependientes de todas las observaciones que le preceden y la naturaleza de esta dependencia es de interés práctico. Los objetivos en los que se centra el análisis de series de tiempo son los siguientes: descripción, explicación, predicción y control (Box et al., 2016; Chatfield & Xing, 2019).

La **descripción** es el primer paso para el análisis de la serie de tiempo, se refiere a la elaboración del diagrama de tiempo y al cálculo de las medidas descriptivas simples de las propiedades de la serie. En el gráfico que se elabore es posible observar la tendencia, estacionalidad o los valores atípicos. Estos últimos son observaciones que parecen no ser consistentes con la mayoría de los datos, su origen puede ser una observación válida causado por un evento extremo o una falla en el registro de los datos; estos valores, si son exactos, indican que el conjunto de los datos no se distribuye bajo una distribución normal, por lo que en muchos modelos se busca ajustarlos, pero existen otros métodos robustos en los que no se requiere de un ajuste (Chatfield & Xing, 2019).

El segundo paso es la **explicación** que se refiere al empleo de la variación de una serie para describir la variación de otra, esto es posible cuando se registran observaciones de dos o más variables, por ejemplo, las ventas se ven afectadas por el precio y las condiciones económicas. Los modelos de regresión múltiple pueden no ser útiles en todos los casos, debido a que no están diseñados para manejar datos de series de tiempo, por lo que se utilizan otros métodos como los modelos de función de transferencia o los sistemas lineales (Chatfield & Xing, 2019).

La **predicción** es el tercer paso y se caracteriza por el uso en el tiempo t de las observaciones en una serie de tiempo para pronosticar su valor en algún tiempo futuro $t + 1$ (Box et al., 2016), es de utilidad principalmente en las series de tiempo relacionadas con el clima, industria, finanzas y economía. Para analizar y obtener proyecciones a futuro de una serie de tiempo se deben de considerar las siguientes características: las observaciones no son independientes entre sí, existe un orden temporal para cada observación y las observaciones sucesivas dependen de las anteriores. Por lo tanto, es posible obtener proyecciones de los valores futuros a partir de las observaciones pasadas. Las proyecciones de series de tiempo son la importancia práctica que se busca en la dependencia que existe entre las observaciones (Box et al., 2016; Chatfield & Xing, 2019).

Las series en las que es posible predecir exactamente los valores futuros, se les llama determinista. Pero es evidente que la mayoría de las series de tiempo son estocásticas, porque el futuro está determinado en parte por las observaciones pasadas, por lo que las proyecciones exactas son imposibles (Chatfield & Xing, 2019) y son pocos los fenómenos en los cuales es posible generar modelos precisos para obtener proyecciones (Rojas & Pomares, 2016). Aunque sí es verdad que los valores futuros están condicionados a la distribución de probabilidad de los valores pasados (Chatfield & Xing, 2019).

La precisión de las proyecciones puede calcularse con los intervalos de confianza o límites de probabilidad en cada lado de cada pronóstico. Estos límites pueden calcularse para probabilidades de 50, 75, 90 o 95 %, que son los más comunes, pero puede utilizarse cualquier otro valor conveniente. Se espera que el valor futuro real, cuando este sea presente, estará dentro de estos intervalos de confianza (Box et al., 2016), lo cual permite tener un margen de precisión y evitar caer en el error de querer obtener modelos que aporten proyecciones precisas que no son posibles de obtener.

Se muestra un ejemplo de proyección en la figura 7, con intervalos de confianza al 95 % de la esperanza de vida de México, con datos reales de 1960 a 2017 y

se muestran 15 años proyectados a futuro, que inician en el origen t para tiempos de entrega $l = 2018, 2019, \dots, 2032$. Se observa que los intervalos de confianza se amplían a medida que aumentan los años en la proyección, lo que refleja una mayor incertidumbre debido a que la serie no es estacionaria y no varía alrededor de un nivel medio fijo (ver páginas 135 a 139 de Box et al., 2016).

El cuarto paso es el **control**, el cual sirve para tener una inspección en diversos sistemas, por ejemplo, en la calidad de algunos procesos de fabricación en los que se capturan los datos periódicamente con la finalidad de tener la serie de tiempo que permita describir las condiciones del proceso y con ello ayudar en la toma de decisiones (Chatfield & Xing, 2019).

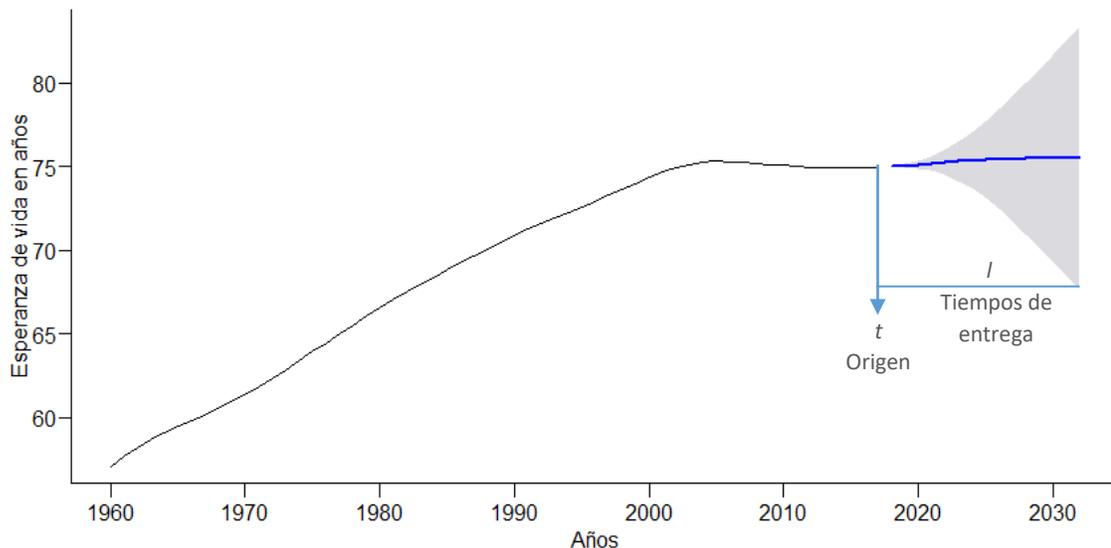


Figura 7. Proyección de la esperanza de vida en México con intervalos de confianza al 95 %. Nota: Se utilizó el método ARIMA. Fuente: Elaboración propia con datos del Banco Mundial, 2019.

2.2.4 Análisis multivariado de series de tiempo

Cuando se estudia un fenómeno es posible encontrar los datos de series de tiempo en dos o más variables de interés $z_{i,t}$, donde $i = 1, 3, \dots, m$, y las observaciones se ordenan de acuerdo con el tiempo t , con los cuales es factible realizar un análisis informativo al considerar series individuales como

componente de una serie multivariada y analizar la serie conjuntamente. Las m variables de series de tiempo, relacionadas como un sistema dinámico, se pueden denotar como el siguiente vector:

$$Z_t = z_{1,t}, z_{2,t}, \dots, z_{m,t},$$

donde: Z_t es la serie de tiempo multivariada o serie de tiempo vectorial, m se refiere al componente o serie de tiempo de la variable en el tiempo t (Wei, 2019; Tsay, 2014).

La característica que diferencia a las series de tiempo multivariante es que sus observaciones dependen no solo del componente i sino también del tiempo t . Además, las observaciones entre $z_{i,s}$ y $z_{j,t}$ pueden estar correlacionadas cuando $i \neq j$, independiente de si el tiempo s y el tiempo t son iguales o no (Wei, 2019). Por lo tanto, los métodos de análisis de series de tiempo multivariantes se utilizan para estudiar las relaciones dinámicas entre las varias series de tiempo que componen al vector Z_t , con el fin de utilizar esta información disponible y adicional para mejorar la precisión de los pronósticos (Box et al., 2016; Tsay, 2014).

La mayoría de los métodos y teorías estadística estándar, basados en muestras aleatorias, no son aplicables a este tipo de series de tiempo multivariante, por lo que se requieren de modelos estadísticos y métodos de análisis que describan adecuadamente las interrelaciones. Un ejemplo es la regresión múltiple de series de tiempo, la cual es un modelo estadístico que describe la relación entre una variable de respuesta y varias variables predictoras. Las variables de series de tiempo son consideradas como vectores y el término de erro sigue un proceso de series de tiempo correlacionado (Wei, 2019).

Aunado a lo anterior, actualmente se tiene otro problema que está relacionado con la alta dimensión en series de tiempo multivariadas. Esto se debe al nuevo desafío que debe manejar el investigador: una cantidad cada vez mayor de datos que se generan por el internet de alta velocidad y el poder y velocidad de las nuevas computadoras. Por lo que, se requieren técnicas, relativamente nuevas,

como la minería de datos para encontrar información útil o patrones ocultos (Wei, 2019).

2.3 Métodos para proyectar series de tiempo

A lo largo de estas últimas décadas en las investigaciones y algunas competencias internacionales se ha trabajado con el objetivo de comparar y encontrar el mejor método con el cual se pueda obtener un modelo para obtener proyecciones fiables o lo más precisas posible (Hyndman, 2020; Makridakis et al., 2020; ver también Makridakis et al., 1982, 1993; Makridakis & Hibon, 1979, 2000). Sin embargo, los datos obtenidos de los fenómenos de la vida real son difíciles de predecir, porque no siguen los procesos teóricos y sería casi imposible crear el modelo preciso para cada serie de tiempo debido a que existen muchos factores, directos e indirectos, que modifican al modelo (Petropoulos & Makridakis, 2020).

A pesar de la complicación que se describe, en diversas áreas del conocimiento se está trabajando para que hoy en día exista una gran cantidad de métodos que sirvan para obtener proyecciones en series de tiempo, por ejemplo, Makridakis y otros investigadores (2020) registraron 61 métodos en La Competencia M4, una de las competencias más grandes y recientes en el mundo. La Competencia M4 sirvió como base para comparar los métodos y clasificar el que tuviera un error menor en el momento de obtener proyecciones puntuales o en intervalos. Estos métodos van desde los métodos estadísticos tradicionales o los que utilizan aprendizaje automático hasta los métodos híbridos y combinaciones novedosas y complejas. A continuación, se describen los métodos más relevantes.

2.3.1 Métodos estadísticos tradicionales

Los métodos estadísticos tradicionales proponen teorías que son fácilmente manejables para obtener modelos que permitan describir el fenómeno y obtener proyecciones, además de no requerir cómputo sofisticado y reduce el tiempo computacional (Makridakis et al., 2018), en comparación a los métodos que

utilizan aprendizaje automático. Por el contrario, se ha visto que los nuevos métodos han demostrado ser más precisos que los más simples o estándar (Makridakis et al., 2020).

En la mayoría de los casos en los que se requiera obtener proyecciones se deberá considerar que éstas dependen del fenómeno, las herramientas y conocimientos con las que se disponga, por lo que es necesario que cada investigador reconozca los diferentes métodos que existen y se seleccione el que sea acorde a las necesidades de cada investigación.

En las siguientes líneas se presentan los métodos estadísticos que son los más representativos por su importancia en uso y precisión, es decir, se han utilizado por una cantidad representativa de investigadores debido a que se obtienen proyecciones confiables y se calculan errores relativamente aceptables. Se consideró mantener el nombre en inglés de los métodos para su representación genérica y en algunos casos se explica su significado porque está relacionado a su manejo.

Además, se hace un aporte adicional a la descripción de los métodos con referencias citadas que fueron seleccionadas de Scopus[®], la cual es la mayor base de datos de citas y resúmenes de revistas científicas, libros y actas de conferencia (Elsevier, 2020). Las citas seleccionadas fueron evaluadas por relevancia, mayor número de citas y más reciente. Los artículos se identificaron mediante la búsqueda en título, palabras clave y resumen de las siguientes palabras: “naïve”, AND “time series” AND “forecast”. Al hacer la búsqueda el nombre del método se cambiaba para corresponder los resultados.

Naïve 1

También conocido como ingenuo 1, es un método equivalente a un modelo de caminata aleatoria (Makridakis et al., 2020). Naïve 1 establece que el valor proyectado para este periodo (t), es igual que el valor real observado en el último período ($t - 1$), por lo que la ecuación se expresa como sigue:

$$Z_t = Y_{t-1},$$

donde: Z_t es el valor pronosticado en el tiempo t y Y_{t-1} es el valor real en el tiempo $t - 1$ (Chen et al., 2008).

Naïve 1 fue utilizado por Athanasopoulos y otros investigadores (2011) para generar proyecciones en datos anuales, con resultados aceptables al compararlo con los siguientes métodos: Theta, ForePro, ETS y ARIMA.

El método se puede implementar en el software estadístico R[®], con la función *navie()* del paquete *forecast* (Hyndman, 2019).

Naïve 2

Naïve 2 es parecido a naïve 1, es decir, se usa la misma ecuación. La diferencia entre los dos métodos es que naïve 2 se aplica a datos ajustados estacionalmente. Por lo tanto, se requiere de una prueba para verificar la significancia de autocorrelación en el término m_{th} en la función de autocorrelación (ACF, por sus siglas en inglés: autocorrelation function). Entonces, dada una serie con las observaciones $n \geq 3m$, frecuencia $m > 1$ y un nivel de confianza del 90 %, los ajustes estacionales se consideran solo si se cumple la siguiente regla:

$$|ACF_m| > 1.645 \sqrt{\frac{1 + 2(ACF_1 + \sum_{i=2}^{m-1} ACF_i^2)}{n}}$$

No se realiza esta prueba en las series de tiempo que no presentan estacionalidad o tienen menos de tres periodos estacionales. Las series de tiempo no estacionales son aquellas series que tienen un valor de $m = 1$.

Si la serie de tiempo no presenta las características anteriores y se considera una serie de tiempo estacional entonces se requiere estimar el componente estacional, lo cual se hace con una descomposición multiplicativa clásica. Esta función se puede realizar con la función *descomponer()* del paquete *stats* de R. Otra forma de calcular el componente o índice estacional es la siguiente: se

obtiene el componente de tendencia aplicando una media móvil de m , después el índice estacional se calcula dividiendo los datos de la tendencia y promediando los resultados, para cada unidad de tiempo, en todos los períodos. La serie ajustada estacionalmente se obtiene al dividir la serie original con los índices estacionales del periodo respectivo.

Para hacer estacionales, los valores obtenidos en las proyecciones, estos se multiplican con los índices respectivos (Makridakis et al., 2020).

Naïve S

El nombre completo del método es Seasonal Naïve o ingenuo estacional. Las proyecciones de este método en el punto t son iguales a la última observación conocida del mismo periodo. La ecuación de Naïve S es la siguiente:

$$Z_t = Y_{t-m},$$

donde: Y_t y Z_t son similares a naïve 1, m es el período estacional y puede ser definido como 12 para mensual, 4 para trimestral, 24 para cada hora y 1 para anuales, semanales o diarios.

El método se puede implementar con la función *snave()* del paquete *forecast* en R (Hyndman, 2019) o usando un modelo equivalente ARIMA (0,0,0)(0,1,0) m , donde m es el período estacional (Makridakis et al., 2020).

Media móvil individual

A este método también se le conoce como SMA por sus siglas en inglés (Single moving average) y está consiste en sumar las observaciones previas juntas y dividir las por el número de observaciones. Con los valores de la media obtenidos con el método SMA permite pronosticar datos futuros. Además, se espera que todos los datos anteriores seleccionados tengan el mismo peso en el valor pronosticado. La ecuación del método se expresa como sigue:

$$M_{t-1} = Z_t = \frac{Y_{t-1} + Y_{t-2} + Y_{t-3} \dots Y_{t-n}}{n},$$

donde: M_{t-1} es el promedio móvil en el tiempo $t - 1$, Z_t es el valor pronosticado para el próximo período; A_{t-1} es el valor real en el periodo $t - 1$ y n es el número de términos en el promedio móvil (Chen et al., 2008).

Suavizado exponencial simple

El método SES (por sus siglas en inglés: single exponential smoothing) permite calcular la influencia de la observación reciente en los valores proyectados y se considera que el valor proyectado para el período actual (t) es igual al proyectado para el período anterior ($t - 1$), más la constante de suavizado (α) multiplicada por el error que el modelo produce para el período anterior ($t - 1$). Los valores anteriores son ponderados por la constante de suavizado, que debe tomar un valor entre 0 y 1, lo cual lo establece el investigador, y se ha visto que cuanto más baja es la constante de suavizado, más peso se les da a los valores anteriores el último valor. La ecuación del método SES es la siguiente:

$$Z_t = \alpha Y_t + (1 - \alpha)Z_{t-1},$$

donde: Z_t es el dato pronosticado para el próximo período en el tiempo t , α es la constante de suavizado ($0 < \alpha < 1$), y Y_t es el valor real en el tiempo t (Chen et al., 2008).

El método SES se puede usar con la función *ses()* o *ets()* del paquete *forecast* en R (Hyndman, 2019), la función se describe a detalle en Hyndman y Khandakar (2008).

Suavizado exponencial doble

El método DES (por sus siglas en inglés: double exponential smoothing) también es conocido como el método de Brown y permite capturar con eficiencia las tendencias lineales crecientes o decrecientes. La ecuación del primer suavizado exponencial del método DES se describe a continuación:

$$Z_t = \alpha Y_t + (1 - \alpha)Z_{t-1} = Z_{t-1} + \alpha(Y_{t-1} - Z_{t-1}),$$

donde: Z_t es la serie de suavizado exponencial simple para el tiempo t , α es la constante de suavizado ($0 < \alpha < 1$), y Y_{t-1} es el valor real en el tiempo $t - 1$.

El segundo suavizado exponencial se define como sigue:

$$Z'_t = Z'_{t-1} + \alpha(Z_t - Z'_{t-1})$$

$$C_t = Z_t + (Z_t - Z'_t)$$

$$T_t = [(1 - \alpha)/\alpha] * (Z_t - Z'_t)$$

$$\hat{Z}_{t+h} = C_t + hT_t,$$

donde: Z'_t es la serie de suavizado exponencial doble para el tiempo t , C_t es la intercepción de la serie proyectada Z' en el tiempo t , T_t es la pendiente de la serie proyectada Z' en el tiempo t , \hat{Z}_{t+h} es el valor de la proyección en el tiempo $t + h$ y h es el número de períodos de tiempo por delante (Chen et al., 2008).

Este método se utilizó en el pronóstico de series financieras con buenos resultados en De la Fuente-Mella et al. (2015).

El método DES se puede usar con la función *ets()* del paquete *forecast* en R (Hyndman et al., 2019), la función se describe en Hyndman y Khandakar (2008).

Suavizado exponencial ajustado a la tendencia

El método ESA (por sus siglas en inglés: exponential smoothing adjusted for trend) también es conocido como el método de Holt o el método de dos parámetros de Holt. Este método es un tipo de suavizado exponencial que se utiliza para manejar una serie de tiempo con tendencial lineal. La diferencia entre ESA y DES es que en el método DES se utiliza solo una constante de suavizado y que los valores de tendencia estimados son sensibles a las influencias aleatorias; además, el método ESA brinda mayor flexibilidad al seleccionar las tasas constantes de suavizado. Las ecuaciones representativas del método son las siguientes:

$$Z_t = \alpha Y_t + (1 - \alpha)(Z_{t-1} + T_{t-1})$$

$$T_t = \beta(Z_t - Z_{t-1}) + (1 - \beta)T_{t-1}$$

$$\hat{Z}_{t+h} = Z_t + hT_t,$$

donde: Z_t es el nuevo valor suavizado, α es la constante de suavizado ($0 \leq \alpha \leq 1$), Y_t es la nueva observación o valor real de la serie en el tiempo t , T_t es la estimación de tendencia en el tiempo t , β es la constante de suavizado para estimar la tendencia ($0 \leq \beta \leq 1$), h son los períodos a proyectar y \hat{Z}_{t+h} son los primeros períodos h pronosticados en el tiempo t (Chen et al., 2008).

El método ESA se puede usar con la función *dshw()* del paquete *forecast* en R (Hyndman et al., 2019), la función se describe a detalle en Hyndman y Khandakar (2008).

Damped

Como su nombre lo indica, el método Damped, amortigua la tendencia lineal y suaviza exponencialmente los datos (Makridakis, et al., 2020), por lo que también se le conoce como método de suavizado exponencial de tendencia amortiguada y se considera referencia importante para la precisión de pronósticos estadísticos, debido a que contiene una variedad de casos que pueden seleccionarse durante el proceso de adaptación. Este método es apropiado para una serie con una tendencia lineal que está desapareciendo y sin estacionalidad. Las ecuaciones base del método Damped pueden escribirse de diferentes formas, las más comunes son las siguientes:

$$Z_t = \alpha Y_t + (1 - \alpha)(Z_{t-1} + \Phi T_{t-1})$$

$$T_t = \beta(Z_t - Z_{t-1}) + (1 - \beta)\Phi T_{t-1}$$

$$\hat{Z}_{t+h|t} = Z_t + (\Phi + \Phi^2 + \dots + \Phi^h)T_t,$$

donde: Z_t es la serie temporal media atenuada después de observar Y_t , α es la constante de suavizado ($0 \leq \alpha \leq 1$), Y_t es la nueva observación o valor real de la serie en el tiempo t , T_t es la estimación de tendencia en el tiempo t , Φ es el amortiguador o parámetro autorregresivo, β es la constante de suavizado para estimar la tendencia ($0 \leq \beta \leq 1$), h son los períodos a proyectar y $\hat{Z}_{t+h|t}$ son los primeros períodos h pronosticados en el futuro (Gardner, 1985; Gardner & McKenzie, 2011).

Gardner y McKenzie (2011) demuestran que el método Damped es un medio de selección automática de una variedad de casos especiales, que van desde un método naïve 1, SES o hasta una tendencia determinista. Además, el método Damped es muy parecido al método ESA y a algunos modelos ARIMA.

Se realizaron ajustes y se presenta estadística de los métodos de suavizado exponencial estándar en Gardner (2006); McKenzie y Gardner (2010) realizaron un modelo de espacio de estado de coeficiente aleatorio para el método Damped y proporcionó resultados óptimos; se comprobó que la optimización de parámetros realiza mejoras en la precisión del pronóstico en la investigación de Gardner y Acar (2019). Aunque, en la competencia M4 sobre pronósticos no tuvo los errores más bajos (Makridakis et al., 2020).

El método ESA se puede seleccionar de la función *ets()* del paquete *forecast* en R (Hyndman et al., 2019).

Theta

El método Theta es un método de pronóstico univariado y se basa en descomponer la serie de tiempo y modificar la curvatura local de la serie a través de un coeficiente “Theta” (letra griega θ), que se aplica directamente a las segundas diferencias de los datos. El modelo Theta está basado en la siguiente ecuación:

$$Z''_n \theta = \theta \cdot Z''_d = Z_t - 2Z_{t-1} + Z_{t-2},$$

donde: Z_n es la serie nueva, θ es el coeficiente Theta, Z_d la serie original y Z_t serie descompuesta en el tiempo t (Assimakopoulos & Nikolopoulos, 2000).

Las series de tiempo que se crean, resultado de la descomposición de la serie original, se denominan líneas Theta y mantienen la media y la pendiente de los datos originales, pero no sus curvaturas. Estas líneas o nuevas series se extrapolan por separado y los pronósticos posteriores se combinan, además, se caracterizan por la mejora de la aproximación del comportamiento a largo plazo de los datos o el aumento de las características a corto plazo, esto dependen del valor del coeficiente Theta (Assimakopoulos & Nikolopoulos, 2000).

El ajuste del modelo Theta que funcionó bien en la competencia de pronósticos M3, principalmente en series mensuales y datos microeconómicos, es el simple con dos líneas Theta: $\theta = 0$ y $\theta = 2$. En el primer caso la serie de tiempo es transformada con regresión lineal y se obtiene una línea recta y en el segundo se extrapola a través de suavizado exponencial simple y se obtienen que duplica las curvaturas locales de la serie de tiempo original (Assimakopoulos & Nikolopoulos, 2000).

Aunque Hyndman y Billah (2003) mostraron que el método Theta puede expresarse de manera mucho más simple y es igual a un método SES con deriva. Se utilizó este método en las siguientes investigaciones: en la investigación de Papacharalampous et al. (2018) sobre la predicción mensual de las temperaturas y precipitaciones se tuvo resultados aceptables; por el contrario, en la predicción operativa de energía fotovoltaica, de Yang y Dong (2018) no fue el mejor método, las combinaciones sí; en los resultados de Theodosiou (2011) el método híbrido de redes neuronales de regresión generalizada y método theta se destacó por su eficiencia; en la predicción de generación de energía solar de AlKandari y Ahmad (2019) los métodos de aprendizaje automático expresaron un error menor, pero los híbridos los superaron.

El método Theta se puede usar con la función `thetaf()` del paquete *forecast* en R (Hyndman et al., 2019).

Media móvil integrada autorregresiva

El método ARIMA (por sus siglas en inglés: autoregressive integrated moving average) también se conoce como el método de Box-Jenkins y es considerada una de las técnicas sofisticadas, en comparación a los métodos descritos anteriormente.

Existen variantes de este método, como es el caso de los modelos ARMA estacionarios que describen cómo una variable independiente (V_t) se relaciona con sus propios valores pasados ($V_{t-1}, V_{t-2}, V_{t-3}, \dots$) y se puede manejar. En el caso de que los tiempos de diferenciación (d) enésimos de una serie de tiempo tienen estructura ARMA, se dice que la serie tiene estructura ARIMA (Box et al., 2016).

Por lo tanto, un modelo ARIMA es un método de ajuste de curvas que utiliza los valores presentes y pasados de variables dependientes para pronosticar valores futuros. Este método ha resultado favorable, por aportar proyecciones con valores de error bajos, en las series de tiempo estacionales. La ecuación con la que se define el proceso ARIMA, de orden (p, d, q) , es la siguiente:

$$\Phi_p(B)\nabla^d V_t = \Theta_q(B)\varepsilon_t,$$

donde: V_t es la variable dependiente el tiempo t , Φ_p es el coeficiente de regresión, B es el operador de retroceso, donde $B^h V_t = V_{t-h}$, ∇^d es la diferencia de d^{th} de la serie V_t , Θ_q es el coeficiente o los pesos llamados, ε_t es el término de los residuales ARIMA (Box et al., 2016).

Para trabajar con series no estacionarias en el método ARIMA generalmente se realiza la diferenciación, esta técnica se usa para transformar a partir de cambios sucesivos una serie no estacionaria en una estacionaria. La estructura de autocorrelación (AC) permite determinar el grado de diferenciación.

Las tres etapas del modelo ARIMA, que se resumen de Box et al. (2016), son las siguientes:

- 1) Identificar el modelo: se consideran los valores de las funciones ACF, la ACF inversa (IACF) y la ACF parcial (PACF) para considerar qué tipo de modelo ARIMA se tiene presente, por ejemplo, cuando la función de ACF es cero, después del retraso q , se observa un modelo de media móvil (MA por sus siglas en inglés: moving average), si las funciones IACF y PACF llegan a cero después del retraso p entonces el modelo es un autorregresivo (AR). Los modelos $AR(p)$ Y $MA(q)$ son fáciles de combinar, lo que da como resultado el modelo $ARMA(p, q)$, el cual es un modelo muy flexible capaz de producir una variedad de estructuras de autocorrelación.
- 2) Estimar los parámetros y prueba de verificación del modelo: en esta etapa hay dos parámetros que se deben de tomar en cuenta, el primero es el error de ruido blanco y el segundo es la estimación de los parámetros. Para verificar la existencia del primero se utiliza la estadística Q , el segundo parámetro se calcula mediante el uso de pruebas. Se recomienda revisar la estimación de parámetros inestables y la posible convergencia para evitar los modelos sobre ajustados y mal especificados.
- 3) Proyecciones de series de tiempo: con el modelo ARIMA es posible obtener proyecciones en series de tiempo estacionarias y no estacionarias. El criterio de información de Akaike aporta información que contribuye a identificar si el modelo es el adecuado para generar los pronósticos ajustados.

El método ARIMA se puede usar con la función *Arima()* o ajustar los coeficientes (p, d, q) , del modelo de forma automática con *auto.arima()* del paquete *forecast* en R (Hyndman, 2019), la función se describe en Hyndman y Khandakar (2008).

Una cantidad importante de investigadores utilizan este método para analizar y generar proyecciones en series de tiempo, debido que se ha usado por mucho tiempo, tienen resultados aceptables, es sencillo (en comparación con otras metodologías de aprendizaje automático o híbridas) y no se requiere de cómputo sofisticado (Contreras et al., 2003; De Gooijer & Hyndman, 2006; Sousa et al.,

2020; Zhang, 2003). Por lo tanto, existen muchas variantes, metodologías, transformaciones y modelaciones de series de tiempo estacionales y no estacionales (Alsharif et al., 2019; Cadenas et al., 2016; Khashei & Bijari, 2011; Sim & Lind, 2019; Singh & Mohapatra, 2019). Si este método es de interés del lector, se recomienda revisar el libro de Box et al. (2016), donde encontrarán detalles sobre temas específicos, como: metodologías, teoría, uso de software estadísticos (con códigos disponibles) y aplicaciones.

2.3.2 Métodos combinados

Los métodos descritos en el apartado 2.3.1 son los referentes básicos utilizados para obtener proyecciones en series de tiempo, en gran medida porque son métodos que tienen varias décadas de haberse diseñado, establecido y comprobado su eficiencia. A pesar de la ventaja en años de uso que tienen los métodos estadísticos tradicionales, estos están siendo adaptados en sistemas complejos (en donde se combinan los métodos) y en otros casos desplazados como los mejores métodos, por su precisión, en comparación con los métodos de aprendizaje automático. Una investigación que corrobora lo anterior es la competencia nombrada M4-Competition, donde se describieron 61 métodos que sirven para obtener proyecciones en series de tiempo (Makridakis et al., 2020).

El ejemplo más popular es el método combinado conocido como: “Comb”. Este método es el promedio aritmético simple de los métodos SES, Holt y Damped, y se utilizó como punto de referencia en la Competencia M4 para evaluar todos los demás métodos utilizados (Makridakis et al., 2020).

2.3.3 Métodos de aprendizaje automático

Los métodos estadísticos tradicionales proponen teorías que son fácilmente manejables para obtener modelos que permitan describir el fenómeno y obtener proyecciones, además de no requerir computo sofisticado y reducir el tiempo computacional (Makridakis, Spiliotis, & Assimakopoulos, 2018), en comparación a los métodos que utilizan aprendizaje automático o inteligencia computacional.

Por el contrario, se ha visto que los nuevos métodos han demostrado ser más precisos que los tradicionales (Makridakis et al., 2020), ver apartado 2.4. Dentro de estos métodos nuevos destacan las redes neuronales artificiales del tipo RNN y variante LSTM (Schmidhuber, 2015), sistemas inmunes, máquinas de vectores de soporte (SVM), técnicas difusas o híbridos de sistemas que combinan cualquiera de los anteriores.

Las RNN son capaces de trabajar con modelos no lineales y, a menudo, son flexibles y robustas con proyecciones en series de tiempo que presentan datos ruidosos. Estas propiedades de las RNN las convierten en una solución única para la predicción de series de tiempo y se han aplicado en trabajos del mundo real, como en predicciones de series de tiempo de la bolsa de valores, del estado meteorológico, tráfico de red y en la producción agrícola (Schmidhuber, 2015). Respecto al sector forestal no se encontró trabajos de investigación relacionados con proyectar variables que dependan del tiempo.

Redes neuronales artificiales

Las redes neuronales artificiales (Artificial neural networks-ANN) se originaron basados en modelos matemáticos de las capacidades de procesamiento de la información de los cerebros biológicos. Aunque ahora se sabe que no tienen mucho parecido, sí se reconoce la importancia que tienen para clasificar patrones. La arquitectura básica de las ANN es la red de pequeños nodos o unidades de procesamiento que se unen a partir de conexiones ponderadas directas (Figura 8). Al comparar el modelo biológico con la arquitectura de las ANN se entiende que los nodos son las neuronas y los pesos de las conexiones son la fuerza de las sinapsis entre las neuronas (Graves, 2012).

Además, una característica de las ANN es que las unidades de una capa se conectan unidireccionalmente con las de la siguiente, en general todas con todas, sometiendo a sus salidas a la multiplicación por un peso que es diferente para cada una de las conexiones (Graves, 2012).

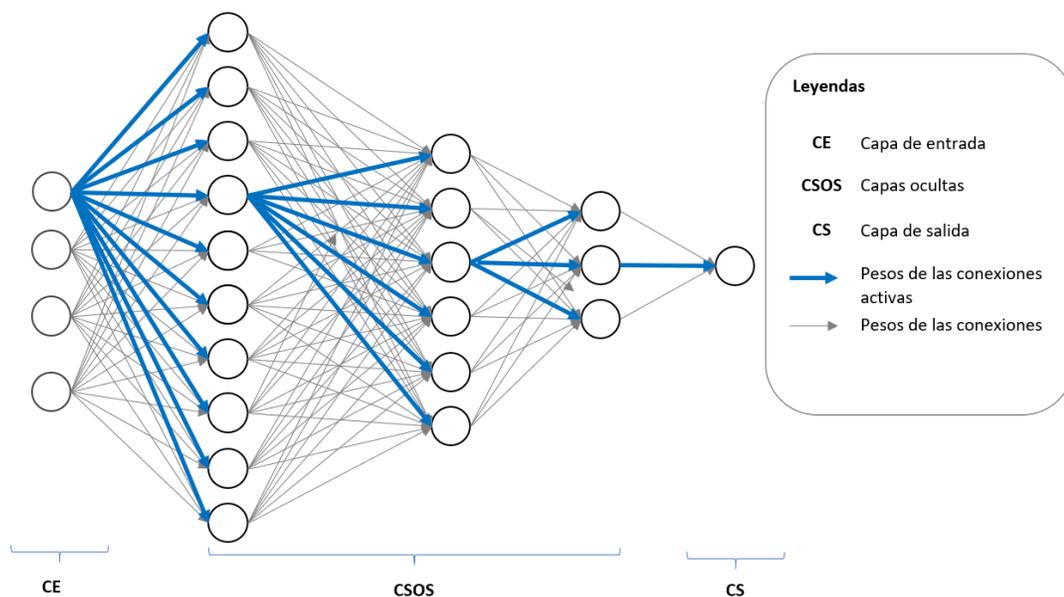


Figura 8. Diagrama de la arquitectura de una red neuronal artificial (ANN). Se da una representación general y simple de los pesos de las conexiones que se encuentran activas durante el entrenamiento o trabajo realizado. Es decir, no todas las neuronas se encuentran activas en el entrenamiento. Fuente: Elaboración propia con información de Graves, 2012.

Redes neuronales recurrentes

Existen muchas variantes de las ANN con características y propiedades diversas, pero el ejemplo clásico es el perceptrón multicapa. La distinción típica es entre las ANN que forman ciclos y las que no los tienen. En el primer caso se encuentran las redes neuronales recurrentes o recurrent neural network (RNN), las cuales también tienen muchas variantes y de estas, se destacan las que presentan una capa oculta y las de varias capas ocultas auto conectadas. Las RNN de múltiples capas son muy utilizadas en el aprendizaje profundo o Deep learning, por tener muchas implicaciones para el aprendizaje de secuencia (Graves, 2012).

Además, las RNN pueden mapear en principio desde toda la historia de entradas previas a cada una de las salidas y las conexiones recurrentes de entrada permiten que persista una “memoria” de entradas anteriores en el estado interno de la red, lo que, al final, influye en la salida (resultado) de la red (Graves, 2012).

Redes neuronales artificiales LSTM

Una de las variantes de las RNN más utilizadas en la proyección de series de tiempo son las redes “Long Short-Term Memory” (LSTM), esto se debe a que presentan los errores más bajos y se obtiene un buen desempeño en los resultados de las proyecciones. Además, permiten modelar sistemas complejos que dependen del tiempo a corto y largo plazo. Una de las diferencias principales de las RNN con las RNN-LSTM es que estas últimas resuelven el problema de gradiente de fuga y por implementar una unidad de procesamiento interno más elaborada, conocida como “celda” (Bianchi et al., 2017; Hochreiter & Schmidhuber 1997; Graves, 2012; Schmidhuber, 2015). Para más información de la teoría del funcionamiento de las RNN-LSTM revisar el capítulo cuatro.

2.4 Análisis bibliométrico en Scopus®

Para hacer el análisis bibliométrico en Scopus® (Elsevier, 2020) se utilizaron las siguientes palabras clave en su respectivo orden de búsqueda:

- a) ((TITLE-ABS-KEY(*prediction*) AND TITLE-ABS-KEY("time series")AND TITLE-ABS-KEY("neural network")))
- b) ((TITLE-ABS-KEY(*prediction*) AND TITLE-ABS-KEY("time series")AND TITLE-ABS-KEY(*regression*)))
- c) ((TITLE-ABS-KEY(*prediction*) AND TITLE-ABS-KEY("time series")AND TITLE-ABS-KEY(**LSTM**)))
- d) ((TITLE-ABS-KEY(*prediction*) AND TITLE-ABS-KEY("time series")AND TITLE-ABS-KEY("support vector machine")))

En el mundo, los principales métodos que se utilizan para la predicción de series de tiempo se encuentran denotados por el número de publicaciones realizadas. En la figura 9, se puede observar que las redes neuronales neural network (NN) han sido el método más utilizado para obtener proyecciones desde 1991, seguido de la regresión y en la actualidad el uso de las RNN-LSTM repuntaron después de sus primeras publicaciones realizadas en 2015, por lo que es un método

relativamente nuevo en los trabajos relacionados con la proyección de series de tiempo, pero con un gran potencial. Además, un tercio de los trabajos publicados se encuentran dentro del área de la Informática o Ciencias de la Computación, seguido de las Ingenierías y las Matemáticas (Figura 10; Elsevier, 2020).

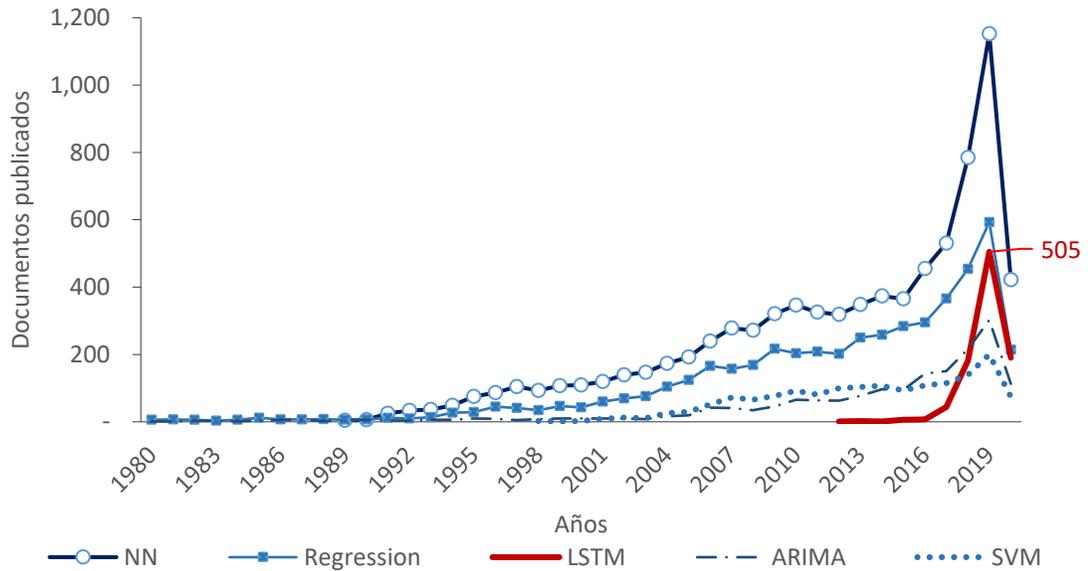


Figura 9. Número de publicaciones encontradas en Scopus® de los métodos más utilizados en la predicción de series de tiempo. Redes neuronales: NN, Regresión: regression y Máquinas de vectores de soporte: SVM. Fuente: Elaboración propia con datos de Elsevier, 2020.

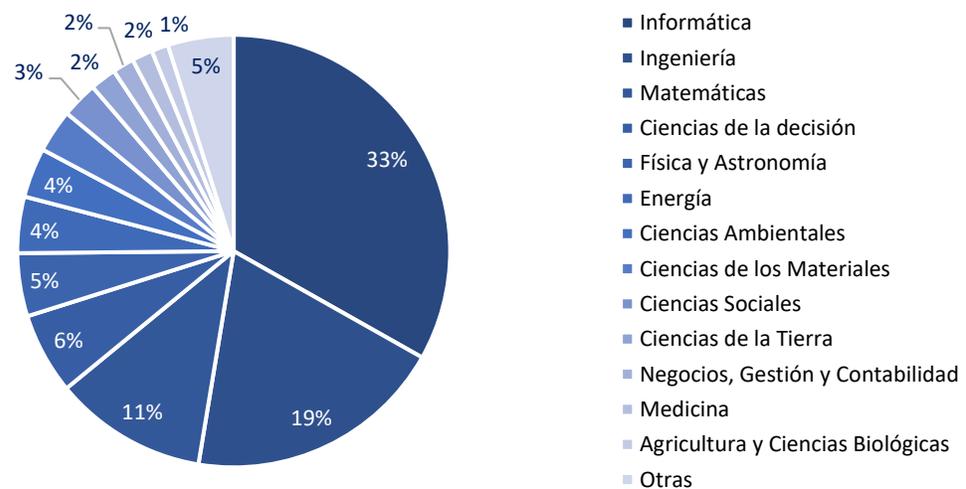


Figura 10. Documentos por área temática. Fuente: Elaboración propia con datos de Elsevier, 2020.

Por otro lado, los principales países que aportaron investigaciones relacionadas con la predicción de series de tiempo empleando las RNN-LSTM son: China con el 41 % del total, seguido de Estados Unidos, India, Corea del Sur e Inglaterra con 11, 7, 4 y 3 % respectivamente (Figura 11). De igual manera, los documentos de conferencia (56 %) y los artículos (41 %) fueron el tipo de documento que más se publicaron (Figura 12; Elsevier, 2020).

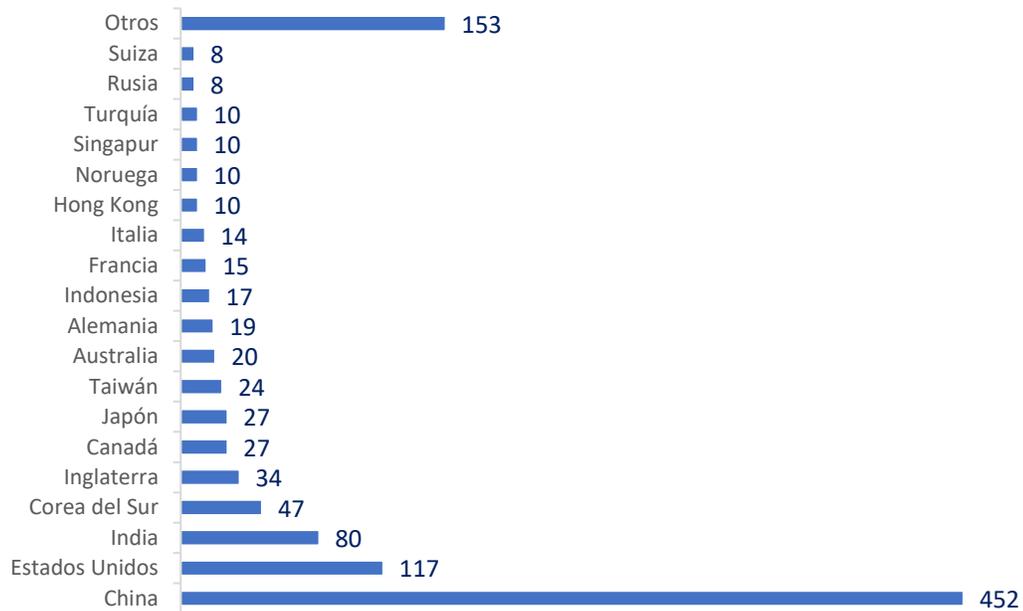


Figura 11. Documentos publicados por país. Fuente: Elaboración propia con datos de Elsevier, 2020.

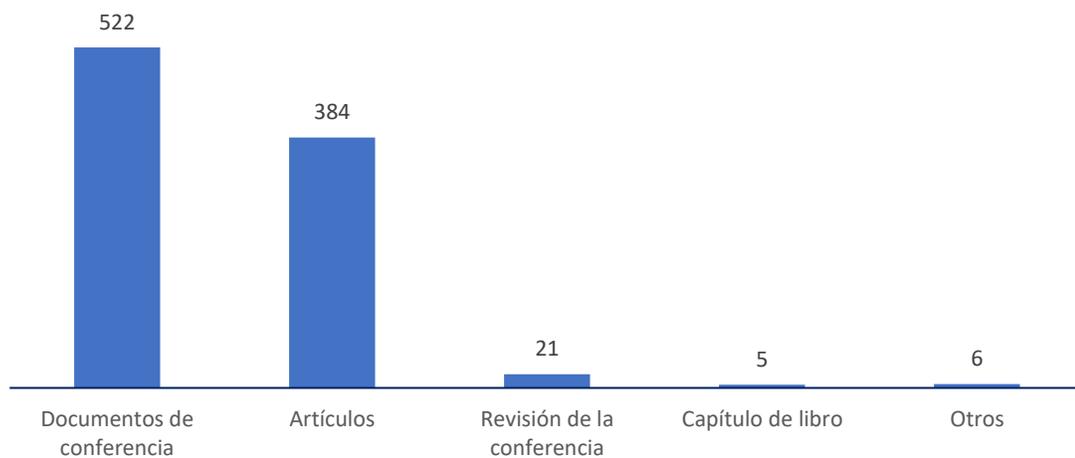


Figura 12. Tipos de documentos publicados relacionados con las RNN-LSTM en la predicción de series de tiempo. Fuente: Elaboración propia con datos de Elsevier, 2020.

2.5 Medidas de desempeño de la proyección

Para obtener proyecciones en series de tiempo es recomendable dejar un porcentaje de los datos reales para comparar los métodos o entrenamientos y seleccionar el que aporte las proyecciones más precisas. En este sentido, cada una de las observaciones reales se comparan con los datos obtenidos en las proyecciones y se hace una evaluación con las medidas de error. Las medidas de error más utilizadas son (Klabi, 2014, Regal et al., 2019):

MSE

El error cuadrático medio o “mean square error” (MSE) se calcula con la ecuación:

$$MSE = \frac{1}{n} \sum_{i=1}^n (h_t - \hat{h}_t)^2,$$

donde: h_t es el valor real de la serie en el tiempo t y \hat{h}_t es el dato predicho.

RMSE

La raíz cuadrada del error cuadrático medio o “root mean square error” (RMSE) sirve para obtener la validación interna del error del modelo y se representa con la siguiente ecuación:

$$RMSE = \sqrt{MSE},$$

donde: h_t es el valor real de la serie en el tiempo t y \hat{h}_t es el dato predicho.

MAPE

El error porcentual absoluto medio o mean “absolute percentage error” (MAPE), el cual expresa la precisión entre modelos como un porcentaje y su ecuación es la siguiente:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|h_t - \hat{h}_t|}{h_t},$$

donde: h_t es el valor real de la serie en el tiempo t y \hat{h}_t es el dato predicho.

Las medidas de error de los métodos utilizados para obtener proyecciones nos permiten comparar y seleccionar el modelo con los ajustes y parámetros que mejor se ajusta al fenómeno de estudio, por lo que son útiles. Sin embargo, en los casos complicados como en los modelos no lineales o series de tiempo sin estacionalidad, tendencia o ciclos es mejor seguir la indicación de Fethi Klabi (2014), en la cual se explica que: en general, es más importante predecir la dirección del cambio de una serie de tiempo en lugar de su dato real, que para los agentes de destino obtener este conocimiento permite planificar un aumento o una disminución de la demanda, contribuyendo, de este modo, a la mejora de la efectividad de sus acciones comerciales.

Es decir, si los resultados obtenidos no son los que se esperaban, por valores altos en las medidas de desempeño, se tienen dos opciones: a) intentar con otros métodos hasta encontrar el adecuado al fenómeno de estudio o b) trabajar con los pronósticos que son relativamente aceptables y orientar la toma de decisiones para lograr una planificación con objetivos más reales. Por lo tanto, si no se hacen intentos para obtener pronósticos no se tendrá una visión del posible futuro de la variable y su estudio o manejo resultarían incompletos.

2.6 Literatura citada

- AlKandari, M., & Ahmad, I. (2019). Solar Power Generation Forecasting Using Ensemble Approach Based on Deep Learning and Statistical Methods. *Applied Computing and Informatics*. En prensa, prueba corregida. <https://doi.org/10.1016/j.aci.2019.11.002>
- Alsharif, M. H., Younes, M. K., & Kim, J. (2019). Time series arima model for prediction of daily and monthly average global solar radiation: The case study of seoul, south korea. *Symmetry*, 11(2), artículo 240. <https://doi.org/10.3390/sym11020240>
- Appendini, K. & Torres-Mazuera, G. (2008). *¿Ruralidad sin agricultura?: perspectivas multidisciplinarias de una realidad fragmentada* (1ª ed.). El Colegio de México, Centro de Estudios Económicos, México, D.F.
- Assimakopoulos, V., & Nikolopoulos, K. (2000). The theta model: a decomposition approach to forecasting. *International journal of forecasting*, 16(4), 521-530. [https://doi.org/10.1016/S0169-2070\(00\)00066-2](https://doi.org/10.1016/S0169-2070(00)00066-2)

- Athanasopoulos, G., Hyndman, R. J., Song, H., & Wu, D. C. (2011). The tourism forecasting competition. *International Journal of Forecasting*, 27(3), 822-844. <https://doi.org/10.1016/j.ijforecast.2010.04.009>
- Banco Mundial. (2019). *Crecimiento del PIB per cápita (% anual) de México*. Recuperado el 2 de enero de 2020 de: <https://datos.bancomundial.org/indicador/>
- Bianchi, F. M., Maiorino, E., Kampffmeyer, M. C., Rizzi, A., & Jenssen, R. (2017). *Recurrent neural networks for short-term load forecasting: an overview and comparative analysis*. Edit. Springer Nature. Cham, Switzerland. <https://doi.org/10.1007/978-3-319-70338-1>
- Bonilla-Moheno, M., & Aide, T. M. (2020). Beyond deforestation: Land cover transitions in Mexico. *Agricultural Systems*, 178, 102734. <https://doi.org/10.1016/j.agsy.2019.102734>
- Bowyer, J. L. (2016). The US Forest Products Industry—past, present, and future. *Drewno. Prace Naukowe. Doniesienia. Komunikaty*, 59(197). <https://doi.org/10.12841/wood.1644-3985.C35.03>
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time series analysis: forecasting and control* (Quinta ed.). John Wiley & Sons. <https://www.wiley.com/en-us/Time+Series+Analysis%3A+Forecasting+and+Control%2C+5th+Edition-p-9781118674918>
- Cadenas, E., Rivera, W., Campos-Amezcu, R., & Heard, C. (2016). Wind speed prediction using a univariate ARIMA model and a multivariate NARX model. *Energies*, 9(2), 109. <https://doi.org/10.3390/en9020109>
- Calva, J. L. & Macías, A. A. (2007). *Desarrollo agropecuario, forestal y pesquero* (1ª ed.). Edit. Porrúa. Vol. 9 UNAM. México.
- Chatfield, C., & Xing, H. (2019). *The Analysis of Time Series: An Introduction with R* (Séptima ed.). CRC Press. www.crcpress.com/The-Analysis-of-Time-Series-An-Introduction-with-R/Chatfield-Xing/p/book/9781498795630
- Chen, G., Pan, S., Hayes, D. J., & Tian, H. (2017). Spatial and temporal patterns of plantation forests in the United States since the 1930s: an annual and gridded data set for regional Earth system modeling. *Earth System Science Data*, 9(2). <https://doi.org/10.5194/essd-9-545-2017>
- Chen, R. J., Bloomfield, P., & Cabbage, F. W. (2008). Comparing forecasting models in tourism. *Journal of Hospitality & Tourism Research*, 32(1), 3-21. <https://doi.org/10.1177/1096348007309566>
- Comisión Nacional del Agua. (2020). *Información climática por estado: Chapingo (DGE), Texcoco*. Recuperado el 1 de enero de 2020 de: <https://smn.conagua.gob.mx/es/informacion-climatologica-por-estado?estado=mex>

- Comisión Nacional Forestal. (2018). *Inventario Nacional Forestal y de Suelos: Informe de Resultados 2009-2014* (Primera ed.). <https://snigf.cnf.gob.mx/resultados-2009-2014/>
- Consejo Nacional de Evaluación de la Política de Desarrollo Social. (2019). Diez años de medición de pobreza multidimensional en México: avances y desafíos en política social [pdf]. Recuperado el 8 de abril del 2020, de https://www.coneval.org.mx/Medicion/MP/Documents/Pobreza_18/Pobreza_2018_CONEVAL.pdf
- Contreras, J., Espinola, R., Nogales, F. J., & Conejo, A. J. (2003). ARIMA models to predict next-day electricity prices. *IEEE transactions on power systems*, 18(3), 1014-1020. <https://doi.org/10.1109/TPWRS.2002.804943>
- Creutzig, F., d'Amour, C. B., Weddige, U., Fuss, S., Beringer, T., Gläser, A., ... & Edenhofer, O. (2019). Assessing human and environmental pressures of global land-use change 2000–2010. *Global Sustainability*, 2, artículo 1. <https://doi.org/10.1017/sus.2018.15>
- De Gooijer, J. G., & Hyndman, R. J. (2006). 25 years of time series forecasting. *International journal of forecasting*, 22(3), 443-473. <https://doi.org/10.1016/j.ijforecast.2006.01.001>
- De la Fuente-Mella, H., Paz-Cruz, A., Conover, R., & Khan, A. (2015). Forecasting of financial series for the Nevada department of transportation using deterministic and stochastic methodologies. *Procedia Manufacturing*, 3, 3317-3324. <https://doi.org/10.1016/j.promfg.2015.07.419>
- Elsevier. (2020). *Scopus*. Recuperado el 1 de enero de 2020 de: <https://www.elsevier.com/solutions/scopus>
- Ferreira, L. N., Vega-Oliveros, D. A., Zhao, L., Cardoso, M. F., & Macau, E. E. (2020). Global Fire Season Severity Analysis and Forecasting. *Computers & Geosciences*, 134, artículo 104339. <https://doi.org/10.1016/j.cageo.2019.104339>
- Gardner, E. S. (1985). Exponential smoothing: The state of the art. *Journal of forecasting*, 4(1), 1-28. <https://doi.org/10.1002/for.3980040103>
- Gardner, E. S. (2006). Exponential smoothing: The state of the art—Part II. *International journal of forecasting*, 22(4), 637-666. <https://doi.org/10.1016/j.ijforecast.2006.03.005>
- Gardner, E. S., & Acar, Y. (2019). Fitting the damped trend method of exponential smoothing. *Journal of the Operational Research Society*, 70(6), 926-930. <https://doi.org/10.1080/01605682.2018.1469457>
- Gardner, E. S., & McKenzie, E. (2011). Why the damped trend works. *Journal of the Operational Research Society*, 62(6), 1177-1180. <https://doi.org/10.1057/jors.2010.37>

- Graves, A. (2012). *Supervised sequence labelling*. In Supervised sequence labelling with recurrent neural networks (pp. 5-13). Springer, Berlin, Heidelberg. <https://doi.org/10.1007/978-3-642-24797-2>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hyndman, R. J. (2020). A brief history of forecasting competitions. *International Journal of Forecasting*, 36(1), 7-14. <https://doi.org/10.1016/j.ijforecast.2019.03.015>
- Hyndman, R. J., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., & Yasmeeen, F. (2019). *Forecast: Forecasting functions for time series and linear models*. Paquete R, versión 8.10. Recuperado el 3 de enero de 2019, de <https://cran.r-project.org/web/packages/forecast/index.html>
- Hyndman, R. J., & Billah, B. (2003). Unmasking the Theta method. *International Journal of Forecasting*, 19(2), 287-290. [https://doi.org/10.1016/S0169-2070\(01\)00143-1](https://doi.org/10.1016/S0169-2070(01)00143-1)
- Hyndman, R. J. & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of statistical software*, 7(3). <https://doi.org/10.18637/jss.v027.i03>
- Khashei, M., & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2), 2664-2675. <https://doi.org/10.1016/j.asoc.2010.10.015>
- Klabi, F. (2014). Forecasting non-residents' monthly entries to Tunisia and accuracy comparison of time-series methods. *The Journal of North African Studies*, 19(5), 770-791. <https://doi.org/10.1080/13629387.2014.949694>
- Makridakis, S., Andersen, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., ... & Winkler, R. (1982). The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of forecasting*, 1(2), 111-153. <https://doi.org/10.1002/for.3980010202>
- Makridakis, S., Chatfield, C., Hibon, M., Lawrence, M., Mills, T., Ord, K., & Simmons, L. F. (1993). The M2-competition: A real-time judgmentally based forecasting study. *International Journal of Forecasting*, 9(1), 5-22. [https://doi.org/10.1016/0169-2070\(93\)90044-N](https://doi.org/10.1016/0169-2070(93)90044-N)
- Makridakis, S., & Hibon, M. (1979). Accuracy of forecasting: An empirical investigation. *Journal of the Royal Statistical Society: Series A (General)*, 142(2), 97-125. <https://doi.org/10.2307/2345077>
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International journal of forecasting*, 16(4), 451-476. [https://doi.org/10.1016/S0169-2070\(00\)00057-1](https://doi.org/10.1016/S0169-2070(00)00057-1)

- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PloS one*, 13(3), artículo e0194889. <https://doi.org/10.1371/journal.pone.0194889>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54-74. <https://doi.org/10.1016/j.ijforecast.2019.04.014>
- McKenzie, E., & Gardner Jr, E. S. (2010). Damped trend exponential smoothing: A modelling viewpoint. *International Journal of Forecasting*, 26(4), 661-665. <https://doi.org/10.1016/j.ijforecast.2009.07.001>
- Merino P., L. (2019), *Crisis ambiental en México: ruta para el cambio*. UNAM. México. https://observatorio.susmai.unam.mx/wp-content/uploads/2019/AgendaAmbiental_RED.pdf#page=165
- Monjarás-Vega, N. A., Briones-Herrera, C. I., Vega-Nieva, D. J., Calleros-Flores, E., Corral-Rivas, J. J., López-Serrano, P. M., ... & Alvarado-Celestino, E. (2020). Predicting forest fire kernel density at multiple scales with geographically weighted regression in Mexico. *Science of The Total Environment*, 718, artículo 137313. <https://doi.org/10.1016/j.scitotenv.2020.137313>
- Newbold, T., Hudson, L. N., Hill, S. L., Contu, S., Lysenko, I., Senior, R. A., Börger, L., Bennett, D. J., Choimes, A., Collen, B., Day, J., Palma, A. D., Díaz, S., Echeverria-Londoño, J., Edgar, M. J., Feldman, A., Garon, M., Harrison, M. L. K., Alhousseini, T., ... & Day, J. (2015). Global effects of land use on local terrestrial biodiversity. *Nature*, 520(7545), 45-50. <https://doi.org/10.1038/nature14324>
- Organización de las Naciones Unidas. (2019). World Population Prospects 2019. Recuperado el 15 de abril del 2020, de <https://population.un.org/wpp/DataQuery/>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2009). La agricultura mundial en la perspectiva del año 2050 [pdf]. Recuperado el 18 de abril del 2020, de [http://www.fao.org/fileadmin/templates/wsfs/docs/Issues_papers/Issues_papers SP/La agricultura mundial.pdf](http://www.fao.org/fileadmin/templates/wsfs/docs/Issues_papers/Issues_papers_SP/La_agricultura_mundial.pdf)
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2016). Evaluación de los recursos forestales mundiales 2015: ¿Cómo están cambiando los bosques del mundo? (Segunda ed.). <http://www.fao.org/3/a-i4793s.pdf>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2019). FAOSTAT [Data set]. Recuperado el 30 de febrero de 2020, de <http://www.fao.org/faostat/es/#data>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2020). Evaluación de los recursos forestales mundiales 2020: Principales

- resultados [pdf]. Recuperado el 9 de mayo del 2020, de <http://www.fao.org/3/ca8753es/CA8753ES.pdf>
- Organización Mundial de la Salud. (2020). Coronavirus disease (COVID-19): Situation Report-126 [pdf]. Recuperado el 25 de mayo del 2020, de https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200525-covid-19-sitrep-126.pdf?sfvrsn=887dbd66_2
- Papacharalampous, G., Tyrallis, H., & Koutsoyiannis, D. (2018). Predictability of monthly temperature and precipitation using automatic time series forecasting methods. *Acta Geophysica*, 66(4), 807-831. <https://doi.org/10.1007/s11600-018-0120-7>
- Pérez H., E. (2013). Prospectiva de la agricultura en el desarrollo de México. *El Cotidiano*, 28(177), 47-60. <https://www.redalyc.org/articulo.oa?id=32527004006>
- Petropoulos, F., & Makridakis, S. (2020). The M4 competition: Bigger. Stronger. Better. *International Journal of Forecasting*, 36(1), 3-6. <https://doi.org/10.1016/j.ijforecast.2019.05.005>
- Potter, K. M., Escanferla, M. E., Jetton, R. M., & Man, G. (2019). Important Insect and Disease Threats to United States Tree Species and Geographic Patterns of Their Potential Impacts. *Forests*, 10(4), artículo 304. <https://doi.org/10.3390/f10040304>
- Regal, A., Morzán, J., Fabbri, C., Herrera, G., Yaulli, G., Palomino, A., & Gil, C. (2019). Proyección del precio de criptomonedas basado en Tweets empleando LSTM. *Ingeniare. Revista chilena de ingeniería*, 27(4), 696-706. <http://dx.doi.org/10.4067/S0718-33052019000400696>
- Rojas, I., & Pomares, H. (2016). *Time series analysis and forecasting: selected contributions from the ITISE Conference*. Springer. <https://doi.org/10.1007/978-3-319-28725-6>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Shumway, R.H., & Stoffer, D. S. (2017). *Time series analysis and its applications: with R examples*. Springer. <https://doi.org/10.1007/978-3-319-52452-8>
- Sim, S. K., Maass, P., & Lind, P. (2019). Wind speed modeling by nested ARIMA processes. *Energies*, 12(1), artículo 69. <https://doi.org/10.3390/en12010069>
- Singh, S. N., & Mohapatra, A. (2019). Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting. *Renewable energy*, 136, 758-768. <https://doi.org/10.1016/j.renene.2019.01.031>
- Soria S., G. & Palacio M., V. H. (2014). El escenario actual de la alimentación en México. *Textos & Contextos (Porto Alegre)*, 13(1), 128-142. <https://doi.org/10.15448/1677-9509.2014.1.16223>

- Sousa Lira, J. M., Gomes Salgado, E., & Alberto Beijo, L. (2020). ARIMA models as an alternative to predict the diffusion of the ISO 14001 standard in Europe. *Journal of Environmental Planning and Management*, 63(2), 275-286. <https://doi.org/10.1080/09640568.2019.1577721>
- Theodosiou, M. (2011). Disaggregation & aggregation of time series components: A hybrid forecasting approach using generalized regression neural networks and the theta method. *Neurocomputing*, 74(6), 896-905. <https://doi.org/10.1016/j.neucom.2010.10.013>
- Tsay, S. R., (2014). *Multivariate time series analysis: with R and financial applications*. John Wiley & Sons. <https://www.amazon.com/Multivariate-Time-Analysis-Financial-Applications/dp/1118617908>
- Uribe-Reyes, J. (2014). El sector agropecuario en México, una historia de marginación. *Análisis Plural*, segundo semestre. ITESO. <http://hdl.handle.net/11117/1241>
- Vargas H., J. G. (2000). Revisión y análisis de las estrategias implementadas para el desarrollo de la agricultura en México. *Theorethikos*, año 3(1). <http://www.redalyc.org/pdf/116/11630106.pdf>
- Wear, D. N., & Greis, J. G. (2012). *The southern forest futures project: summary report*. (Gen. Tech. Rep. SRS-GTR-168). Asheville, NC: USDA-Forest Service, Southern Research Station. https://www.srs.fs.fed.us/pubs/gtr/gtr_srs168.pdf
- Wear, D. N., & Greis, J. G. (2013). *The southern forest futures project: Technical report*. (Gen. Tech. Rep. SRS-GTR-178). Asheville, NC: USDA-Forest Service, Southern Research Station. https://www.srs.fs.fed.us/pubs/gtr/gtr_srs178.pdf
- Wei, W. W. S. (2019). *Multivariate time series analysis and applications*. John Wiley & Sons. <https://www.wiley.com/en-us/Multivariate+Time+Series+Analysis+and+Applications-p-9781119502852>
- Yang, D., & Dong, Z. (2018). Operational photovoltaics power forecasting using seasonal time series ensemble. *Solar Energy*, 166, 529-541. <https://doi.org/10.1016/j.solener.2018.02.011>
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)

3 ANÁLIS DE DATOS DEL SECTOR FORESTAL DE MÉXICO Y EL MUNDO

ANALYSIS OF DATA FROM THE FOREST SECTOR IN MEXICO AND THE WORLD

Javier Medina-Hernández³, Francisco José Zamudio-Sánchez¹, Alejandro Ismael Monterroso-Rivas², Gabriel Arcángel Rodríguez-Yam¹, Adriana Ávalos-Vargas¹

HIGHLIGHTS

- El análisis de las bases de datos del sector forestal es útil para describir el panorama actual de dicho sector.
- A nivel mundial, el continente americano es el que cuenta con la mayoría de la superficie de bosque, destacan: Brasil, Canadá y Estados Unidos.
- Se pierde biodiversidad por el aumento en el área de bosque plantado.
- Un tercio de la superficie forestal mexicana son bosques con vegetación secundaria.
- En México se produce principalmente madera de pino y éste se distribuye en solo el 16 % del área forestal nacional total.

3.1 Resumen

Introducción: La información de los bosques de México y el mundo está distribuida en varios informes, inventarios y bases de datos de diversas instituciones. Se espera que la Evaluación de los Recursos Forestales Mundiales 2020 (FRA 2020) se convierta en el depósito de información más completo y actualizado. Respecto a los datos generales de los bosques del mundo, se calculó que se tienen 3,999 millones de hectáreas (ha) de bosque, de las cuales

Universidad Autónoma Chapingo, ¹División de Ciencias Forestales, ²Departamento de Suelos. Km 38.5 Carretera México-Texcoco. C. P. 56230. Chapingo, Texcoco, Estado de México. México.

México ocupa el 3.4 %. Además, la superficie arbolada, con importancia para la producción forestal, representa el 48 % de la superficie forestal nacional. México es un país megadiverso, por lo que se requiere de la implementación y adecuación de manejos forestales sostenibles (MFS) para aumentar los ingresos de los productores y conservar los recursos para las generaciones futuras.

Objetivos: Realizar el análisis de los datos del sector forestal de México y el mundo con el uso de bases de datos y programas estadísticos para describir el panorama actual de los bosques y los MFS.

Materiales y métodos: Los datos anuales de las variables seleccionadas se descargaron de las bases de datos, anuarios e inventarios del sector forestal de México y el mundo. Después se representaron en gráficas y cuadros. Y se realizó, un análisis de todos los datos descargados.

Resultados y discusión: La degradación de los bosques de México y el mundo va en aumento, por lo que también se observó un incremento en las áreas protegidas, donde destacan: Estados Unidos (EU), Brasil, México, Rusia, Australia, El Congo, Venezuela y Canadá. Aunque, la mayor extracción de madera la realizó India, EU, Brasil, Rusia y Canadá, por orden de importancia, los últimos cuatro países tienen establecidos MFS, que les permite a sus productores un ingreso económico alto y conservan parte de sus recursos a futuro. Por su parte, México se caracterizó por presentar varios ecosistemas de importancia forestal, como los bosques, las selvas y los manglares con 17.9, 15.3 y 0.5 % del territorio nacional respectivamente (196 millones de ha). Los dos primeros son los que presentan un porcentaje alto de degradación.

Conclusión: Se requieren de datos actualizados y con mayor precisión para obtener un análisis más completo y confiable. El panorama descrito para México y el mundo exigen un MFS enfocado a cada región.

Palabras clave: bases de datos; manejo forestal sostenible; toma de decisiones.

3.2 Introducción

A nivel mundial, las actividades antropogénicas como el manejo, los incendios y el cambio de uso de suelo para la ganadería, agricultura y zonas urbanas han sido los factores responsables de modificar la estructura y sistema que conforman los bosques. Las consecuencias de estos cambios son los eventos climáticos extremos y la pérdida masiva de biodiversidad en varios biomas de todo el mundo. Dichos problemas van en aumento por el crecimiento de la población, el calentamiento global y la invasión de especies no nativas (Ferreira et al., 2020; Menezes et al., 2019; Mondal et al., 2019; Newbold et al., 2015).

Para el caso de México, se requiere de estudios en los que se pueda determinar el límite de cuánta naturaleza estamos preparados para perder. Además, de contrarrestar las condiciones desfavorables del mercado, la falta de financiamiento, el desafío en el desarrollo y la implementación de los planes de manejo forestal adecuados a cada región (Siry et al., 2018) que permitan establecer las acciones para retener todas las especies, comunidades y ecosistemas necesarios, con el fin de mantener los sistemas esenciales de soporte vital y que la sociedad se encuentre en un espacio operativo y seguro (Maron et al., 2018).

Frente a la creciente degradación y pérdida de los bosques de México y el mundo es necesario cambiar la visión que se tiene de los bosques, enfocando la atención a temas relacionados con el manejo forestal sostenible (MFS) (Gryazkin et al., 2019; Linser et al., 2018; Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO], 2016). La FAO (2019b) define al MFS como: “optimizar sus beneficios, incluida la madera y las contribuciones a la seguridad alimentaria, para satisfacer las necesidades de la sociedad de una manera que conserve y mantenga los ecosistemas forestales en beneficio de las generaciones presentes y futuras”.

Sin embargo, para que los bosques perduren al largo plazo, en beneficio de las generaciones presentes y futuras, es vital comprender la situación actual (FAO,

2016) de las condiciones y usos de los bosques del mundo para tener las bases que permitan evaluar, desarrollar y hacer cumplir las políticas, leyes, y técnicas de gestión forestal multipropósito que respondan a los problemas de los bosques (FAO, 2019b; Wear & Greis, 2013).

La deforestación, la degradación y la expansión forestal son algunos de los parámetros en los que se debe trabajar con en análisis de datos, con el fin de que se utilicen estos estudios para administrar con eficiencia las áreas forestales del mundo. Los avances en la tecnología permiten realizar estas estimaciones y obtener información sobre la superficie de la Tierra y el cambio que esta sufre a lo largo del tiempo, un logro muy importante en la actualidad, pero se requiere que sea aún más precisa (Olofsson et al., 2020).

La FAO (2016) establecen que es crucial que la información de los recursos forestales sea, además, actualizada y confiable para apoyar en la toma de decisiones, enfocada en la inversión, formulación de políticas ambientales, desarrollo del sector forestal y, Siry et al. (2018) y Linser et al. (2018) explican que estos datos sirven para evaluar, en el presente, las preocupaciones continuas sobre las tendencias de los criterios e indicadores de los bosques.

Por lo tanto, en este trabajo de investigación se tiene el objetivo de generar el análisis de los datos del sector forestal de México y el mundo con bases de datos y programas estadísticos para proporcionar un panorama de los bosques y el uso de un MFS.

3.3 Materiales y métodos

Se realizó una búsqueda de las variables clave que describen el sector forestal de México y el mundo en las diversas bases de datos, anuarios, reportes e inventarios forestales. Después se descargaron los datos de las siguientes bases de datos e inventarios seleccionados:

- Evaluación de los Recursos Forestales Mundiales 2015 (FRA; FAO, 2016, 2020b).

- Base de Datos Estadísticos Corporativos de la FAO (FAOSTAT; FAO, 2019a).
- Comisión Nacional Forestal (CONAFOR, 2018).
- Organización de las Naciones Unidas (ONU, 2019).
- Sistema Nacional de Información y Gestión Forestal (SNIGF, 2018).
- Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT, 2016, 2019a, 2019b).
- Instituto Nacional de Estadística y Geografía (INEGI, 2019).

Los datos de cada una de las variables fueron ordenados, clasificados y analizados en diversas gráficas y tablas dinámicas elaboradas en el software Microsoft Excel y R Studio®. Posterior a la presentación de los datos se realizó un análisis respectivo para cada variable de estudio.

3.4 Resultados y discusión

3.4.1 Situación actual de los bosques del mundo

Las perspectivas e información más completa y confiable de los bosques a nivel mundial se encontraron en el reporte nombrado “Global Forest Resources Assesment” 2015 (FRA 2015), realizado por la FAO cada 10 años a partir de 1948 hasta el 2000 y después del 2000 se ha elaborado cada 5 años. La FRA 2015 contiene el panorama sobre la condición, gestión y usos de los recursos forestales de 234 países, es decir, el 88 % de los bosques del mundo (FAO, 2016). Actualmente se trabaja en el FRA 2020 que pretende convertirse en el depósito de información forestal más actualizada del mundo, con la implementación de una plataforma innovadora que permitirá recopilar, revisar y generar informes de la situación de los bosques a nivel nacional, regional o mundial (FAO, 2018, 2020a).

En los avances del FRA 2020 se calculó que en el mundo existen 4,060 millones ha, cifra que equivale al 31 % del total de superficie de tierra en el mundo, de la

cual la zona tropical, boreal, templada y subtropical poseen el 45, 27, 16 y 11 %, respectivamente. Así mismo, solo cinco naciones cuentan con el 54 % de esta superficie: Rusia, Brasil, Canadá, Estados Unidos de América (EUA) y China, con 815, 497, 347, 310 y 220 millones de ha para cada caso. (FAO, 2020b).

La reforestación anual promedio fue de 27 millones de ha, por lo que los bosques plantados están ocupando una mayor superficie, con una tasa de crecimiento anual del 1.8 %, el cual representa el 7 % del área forestal mundial. Por el contrario, la pérdida de cambio anual de los bosques naturales se calculó en -0.24 % (Figura 13). Esta situación ocasionará diversos problemas, principalmente en la pérdida de biodiversidad (FAO, 2016).

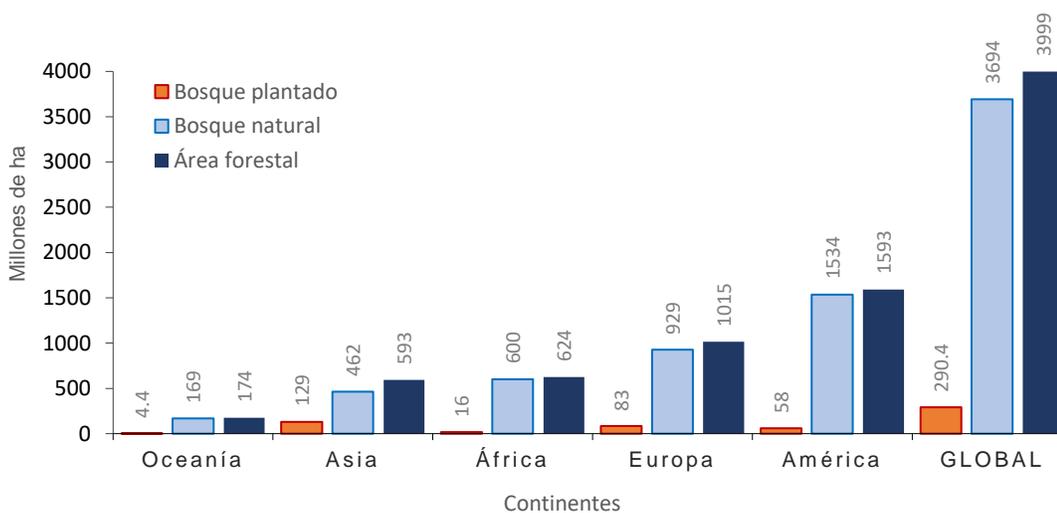


Figura 13. Área forestal global y por continentes. Fuente: Elaboración propia con datos de la FAO, 2016.

Además, para el año 2015 se detectaron estos inconvenientes: un crecimiento del 11 % en el área forestal ocupada por especies leñosas invasoras, el equivalente a 79 millones de ha; las regiones tropicales presentaron la mayor parte del bosque convertido a otros usos de la tierra, en el periodo 1990 y 2015, por lo que se tiene una disminución en el área forestal per cápita del 35 %; el cambio anual del área forestal se presenta principalmente en los países de ingresos medios-bajos y bajos, con una reducción de 1.5 (2010 a 2015) y 0.5 millones de ha (1990-2000 a 2010-2015); la propiedad privada va en aumento,

con una tasa de crecimiento anual del 1 %, mientras que la propiedad pública disminuye con una tasa anual del -0.24 % (FAO, 2016).

Los diez países que cuentan con la mayor área forestal representan el 67 % del total mundial, pero son solo cinco países los que poseen más de la mitad (54 %) de la superficie de bosque en todo el mundo; Rusia, Brasil, Canadá, EU y China. Además, se obtuvo una pérdida anual de 1,055 ha al comparar las pérdidas y ganancias de los diez países que obtuvieron las cifras más altas para el periodo 2010-2015 (Cuadro 1). Es necesario destacar que esta disminución del área forestal tendría valores más bajos sino fuera por los esfuerzos que China ha realizado en la reforestación de sus bosques, superando en 1.2 millones de ha anuales reforestadas a Australia que fue el segundo país con mayor ganancia en el área forestal (FAO, 2016).

Dado el crecimiento de la población y la demanda de productos forestales se debe de tener en cuenta qué países pierden o ganan área forestal en el futuro, para lo cual son importantes los planes de manejo. En el 2010, 167 países reportaron tener un plan de manejo forestal y estos planes cubren más de la mitad de su área de bosque, lo que equivale a 2,100 millones de ha aproximadamente (FAO, 2016).

Cuadro 1. Los diez países con la mayor superficie, pérdida y ganancia forestal en el mundo.

Superficie forestal (2015)			Pérdida neta anual del área forestal (2010-2015)		Ganancia neta anual del área forestal (2010-2015)	
País	Miles de ha	% del total mundial	País	Miles de ha	País	Miles de ha
Rusia	814,931	20	Brasil	984	China	1542
Brasil	493,538	12	Indonesia	684	Australia	308
Canadá	347,069	9	Myanmar	546	Chile	301
EUA	310,095	8	Nigeria	410	EUA	275
China	208,321	5	Tanzania	372	Filipinas	240
El Congo	152,578	4	Paraguay	325	Gabón	200
Australia	124,751	3	Zimbabue	312	Laos	189
Indonesia	91,010	2	El Congo	311	India	178
Perú	73,973	2	Argentina	297	Vietnam	129
India	70,682	2	Bolivia	289	Francia	113
TOTAL	2,686,948	67	TOTAL	4530	TOTAL	3475

Fuente: Elaboración propia con datos de la FAO, 2016.

La superficie de bosque global establecida legalmente como áreas protegidas en el 2015 fue cercano a los 651 millones de ha (17 % del total mundial). Los países con la mayor superficie destinada a las áreas protegidas son Brasil, EU, Indonesia, China, El Congo y Venezuela con 206, 33, 32, 28, 24 y 24 millones de ha respectivamente, los seis países representan el 53 % del total de ha protegidas. Sin embargo, en el mundo se extrajeron cerca de 3 mil millones de metros cúbicos de madera para el año 2011 (Figura 14), el equivalente al 0.6 % del stock de cultivo total; alrededor de la mitad de las extracciones de madera son para combustible, donde los países de ingresos medio-bajos y bajos utilizan el 86 y 93 % para este fin respectivamente, por el contrario, los países de ingresos altos tienen un uso de solo el 17 %, el resto es para la industria (FAO, 2016).

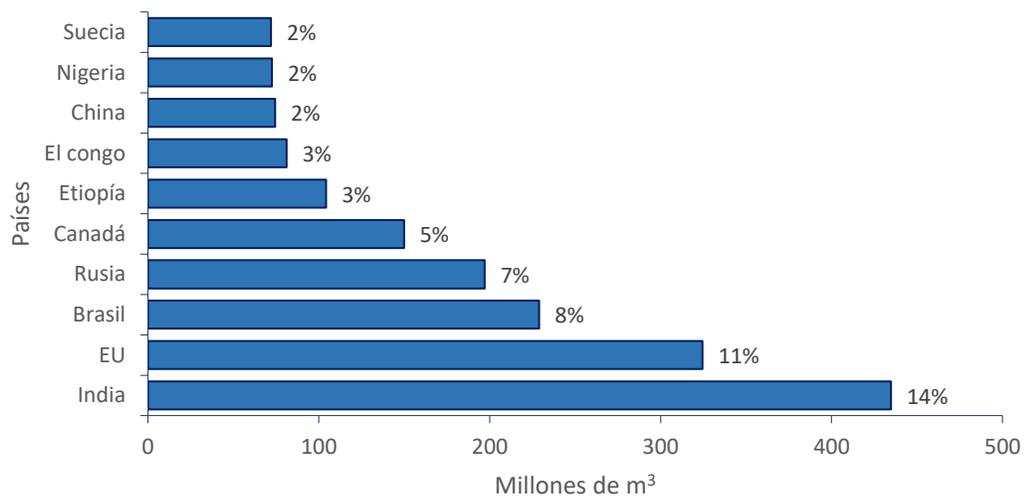


Figura 14. Los países con mayor extracción de madera en el año 2011. El porcentaje se estimó con relación al total mundial de 3 mil millones de m³. Fuente: Elaboración propia con datos de la FAO, 2016.

Los países con ingresos altos designaron poco más de 600 millones de ha para la producción, la mitad del total mundial registrado para esta actividad en el año 2015, mientras que los países de ingresos bajos registraron solo el 8 % del total. Además, para el mismo año, alrededor de mil millones de ha de bosque fueron designados para usos múltiples, principalmente para la producción de productos forestales madereros y no madereros. Del total de la superficie registrada para

usos múltiples dos tercios se encuentran en países de altos ingresos y solo una décima parte en países de bajos ingresos (FAO, 2016).

Por el contrario, los países con mayor área forestal designada para la conservación de la biodiversidad cubren el 59 % del total de superficie del mundo para el 2015, el cual es cercano a los 524 millones de ha y representa el 13 % del bosque mundial (Figura 15). Para el caso de México, la superficie designada para este fin equivale al 42 % del total de su área forestal reportada (FAO, 2016).

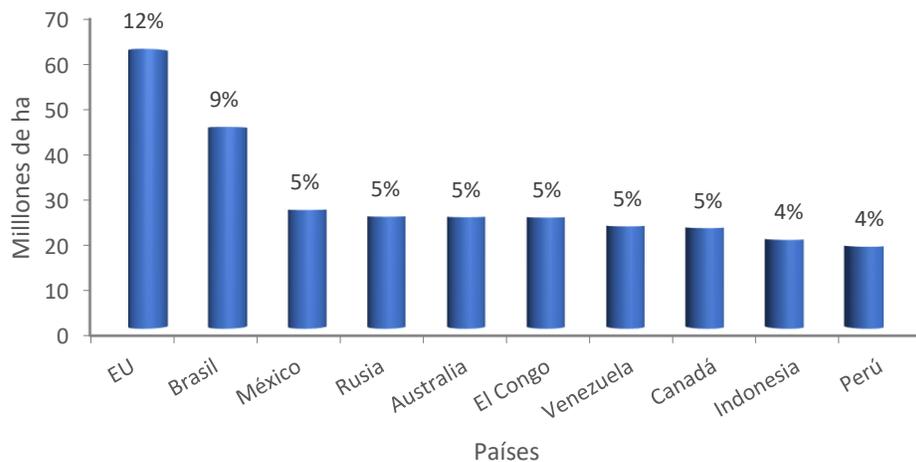


Figura 15. Los diez principales países con área forestal designada para la conservación de la biodiversidad en el año 2015. El porcentaje se obtuvo con relación a los 524 millones que se calcularon para este rubro a nivel mundial. Fuente: Elaboración propia con datos de la FAO, 2016.

El impacto que la sociedad ejerce sobre los recursos naturales es uno de los indicadores utilizados por Jacobson et al. (2019) para establecer el panorama actual de los diferentes biomas del mundo. Los autores obtuvieron que actualmente todos los biomas del mundo están siendo afectados, pero en los biomas que se encontró un mayor impacto fue en los bosques tropicales secos y los pastizales templados, seguido de los biomas mediterráneos, bosques templados de hoja ancha y bosques tropicales de coníferas (Figura 16). A pesar de lo anterior, estimaron que el 56 % de la superficie del planeta permanece como áreas de bajo impacto (menos el hielo y las nieves perpetuas), distribuidas de manera no aleatoria en todos los continentes y biomas.

Por lo tanto, se requiere de un enfoque interdisciplinario para evaluar las actividades antropogénicas que afectan los bosques (Watson & Greis, 2017). Además, estas amenazas son consideradas como una emergencia mundial con límite de tiempo, por lo que se están creando y reevaluando los Acuerdos Globales para la Naturaleza (AGN). Dichos acuerdos están diseñados para proteger el 30 y 50 % de la biosfera terrestre para el 2030 y 2050 respectivamente, con el fin de conservar el patrimonio ecológico que necesitarán las generaciones futuras (Dinerstein et al., 2017, 2019; Jacobson et al., 2019).

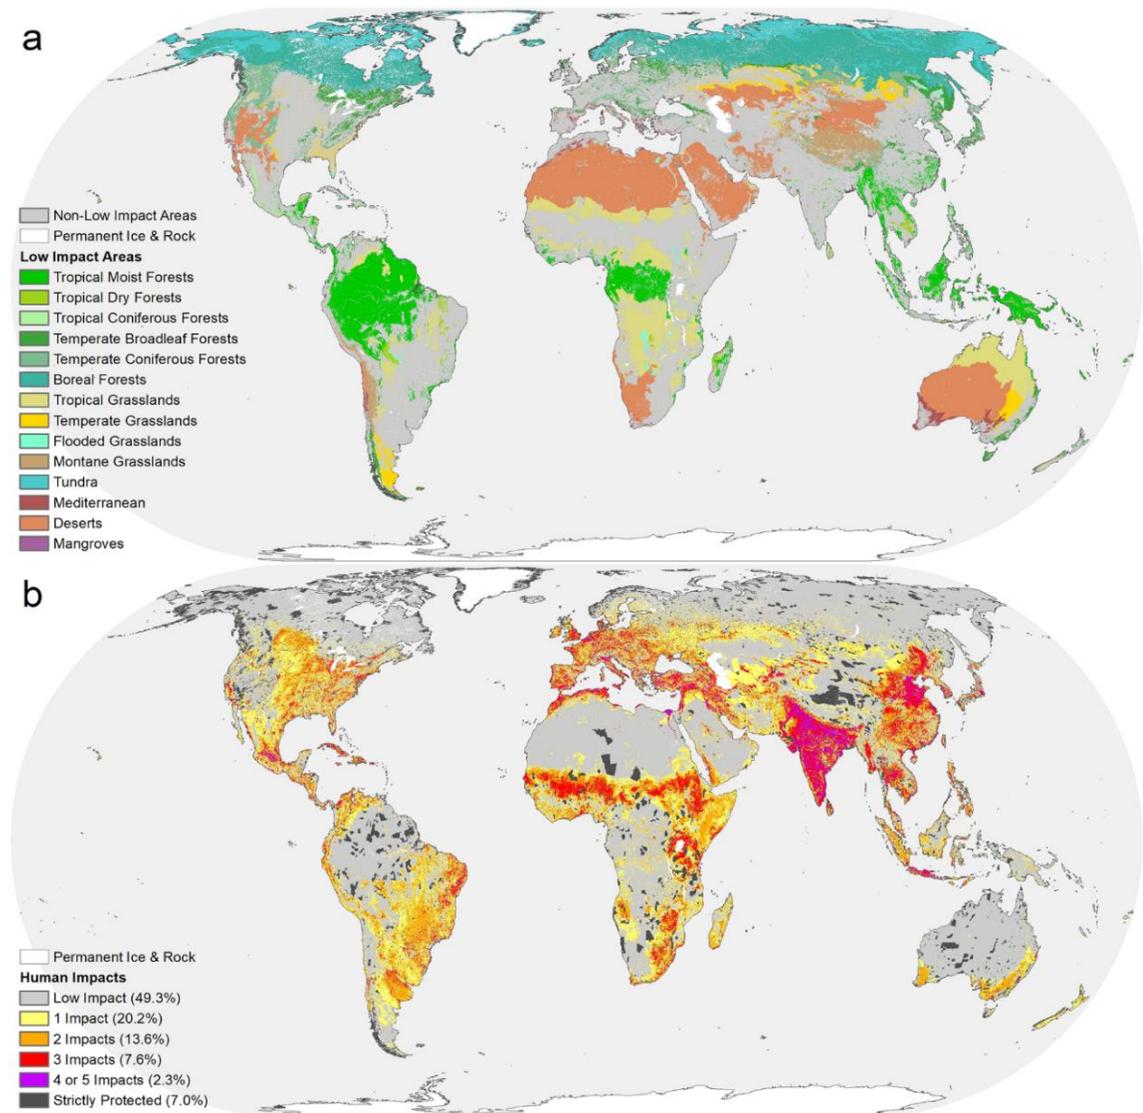


Figura 16. Situación actual de los biomas del mundo: a) Áreas de bajo impacto en los diferentes biomas y b) intensidad de los impactos humanos. Fuente: Tomado de Jacobson (2018).

Estos acuerdos ayudarán también a promover el desarrollo económico, empoderar a los pueblos indígenas en la protección de sus tierras soberanas y harán que el planeta sea más habitable para la humanidad (Dinerstein et al., 2019). Además, se requiere un enfoque multifacético, en el que se conserven los sistemas naturales utilizados por la humanidad para los servicios ecosistémicos y no restaurar solo las áreas protegidas (Maron et al., 2018).

El empleo de la gobernanza ambiental, los acuerdos de administración de la tierra, los trabajos de conservación privados y el MFS son otras herramientas necesarias para tener esquemas de servicios ecosistémicos (Watson & Greis, 2017) y con ellos trabajar en el rescate de las áreas forestales para contrarrestar el problema permanente de la fragmentación, ocasionada por las actividades humanas (Jacobson et al., 2019), y priorizar en la restauración y conservación de las zonas que albergan las últimas especies y muestras de cualquier tipo de ecosistema para conseguir que la biodiversidad y los diversos servicios vitales se mantengan a el largo plazo y a cualquier escala geográfica (Watson & Greis, 2017), como son: agua y aire limpio, captura de carbono, producción, áreas de recreación y mitigación del cambio climático (FAO, 2019b).

Además, el MFS debe de centrarse en desarrollar técnicas que sean cada vez más eficientes en el uso de la tierra y los recursos para reducir la degradación ambiental (Dinerstein et al., 2019). Dentro de las alternativas se tiene el aprovechamiento de los recursos forestales no maderables como: las resinas, los hongos, las plantas medicinales y comestibles, la corteza, la tierra de monte, el ecoturismo, biocombustibles, etc. En la actualidad, se está lejos de aprovechar al máximo dichos recursos forestales porque no se tiene una metodología económica para la evaluación integral y, en general, la recolección se realiza de forma espontánea e incontrolable (Gryazkin et al., 2019).

La migración de la población del campo a las ciudades que ocurre en la mayoría de los países, debido a cambios socioeconómico, es otro fenómeno que podría ayudar a la restauración de las áreas protegidas y a la recuperación de tierras

abandonadas. Se estima que para el 2050 el 70 % de los habitantes de varias partes del mundo vivirán en ciudades (Dinerstein et al., 2017).

3.4.2 Pasado y presente del sector forestal de México

El Inventario Nacional Forestal y de Suelos (INFyS) 2009-2014 es el reporte más reciente que proporciona información integral, periódica y actualizada del sector forestal mexicano. Solo se han realizado dos informes con la misma metodología, el primer INFyS se realizó en el periodo 2004-2009. La información de estos 10 años de muestreo permite hacer comparaciones de los principales indicadores y tendencias del sector forestal, algo que no fue posible con los cuatro inventarios forestales que se hicieron, anteriores a los INFyS, con metodologías diferentes y en periodos desiguales, estos son: Primer Inventario Forestal 1961-1985, Inventario Nacional Forestal de Gran Visión 1991, Inventario Nacional Forestal Periódico 1994 y el Inventario Forestal Nacional 2000 (CONAFOR, 2012, 2018).

En el INFyS del ciclo de muestreo 2009-2014 se utilizó como marco de referencia la Carta de Uso de Suelo y Vegetación a escala 1:250,000 del INEGI, Serie VI-2014 para conocer la distribución y superficie de la cubierta vegetal. Con los datos actualizados para el año 2014 se calculó poco más de 137.8 millones de ha de superficie forestal el equivalente al 70.5 % del territorio de México (Cuadro 2) y dentro de esta área de bosque se tiene un registro de 54 tipos de vegetación organizadas en 11 formaciones forestales (CONAFOR, 2018).

Además, la vegetación primaria y secundaria son dos parámetros utilizados para identificar el estado sucesional de la vegetación. El primer estado es la vegetación que no presenta indicios de perturbación y corresponde al 48 % del territorio nacional; en el segundo estado se describe como el bosque que ha sido alterado, modificado o eliminado, este estado representa el 22.1 % del territorio nacional, es decir aproximadamente un tercio del área forestal está siendo alterada (Figura 17). El problema es mayor en las selvas altas-medianas, selvas bajas, bosque de latifoliadas y bosque de coníferas-latifoliadas con cerca de

10.33, 9.53, 4.87 y 4.81 millones de ha, juntos suman el 68 % del área de vegetación secundaria (CONAFOR, 2018).

Cuadro 2. Superficie forestal de México organizada por ecosistemas y formaciones forestales.

Ecosistema	Formación forestal	Vegetación primaria		Vegetación secundaria		Total	Proporción (%)	
		ha	%	ha	%		ha	SF
Bosques	Coníferas	5,210,734	64	2,892,357	36	8,103,091	5.9	4.1
	Coníferas y latifoliadas	8,136,658	63	4,813,113	37	12,949,771	9.4	6.6
	Latifoliadas	6,493,143	58	4,867,357	43	11,360,500	8.2	5.8
	Bosque mesófilo	823,141	46	963,924	54	1,787,065	1.3	0.9
Selvas	Selvas altas y medianas	3,236,41	24	10,325,893	76	13,562,305	9.8	6.9
	Selvas bajas	6,931,309	42	9,532,891	58	16,464,200	11.9	8.4
Otras asociaciones		533,828	99	6,332	1	540,160	0.4	0.3
Manglar		842,976	90	96,660	10	939,636	0.7	0.5
Subtotal arbolado		32,208,200	49	33,498,526	51	65,706,727	47.7	33.6
Matorral xerófilo	Zonas semiáridas	18,083,477	89	2,246,993	11	20,330,470	14.7	10.4
	Zonas áridas	32,733,431	91	3,241,108	9	35,974,540	26.1	18.4
Otras áreas forestales		11,488,048	73	4,345,353	27	15,833,401	11.5	8.1
Total del área forestal		94,513,157	69	43,331,981	31	137,845,138	100	70.5
Áreas no forestales						55,063,142		28.1
Agua						2,752,845		1.4
Total nacional						195,661,124		100

Notas: SF: Superficie forestal y SN: Superficie Nacional. Fuente: Elaboración propia con datos de la CONAFOR, 2018.

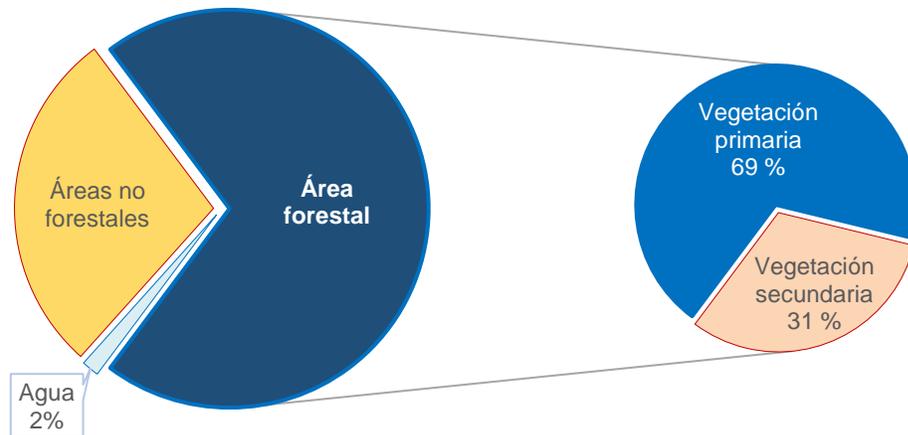


Figura 17. Territorio de México dividido por uso del suelo en general y el grado de alteración de la vegetación forestal. Fuente: Elaboración propia con datos de la CONAFOR, 2018.

Las zonas arboladas comprenden los siguientes ecosistemas: bosques (bosque mesófilo de montaña, coníferas, latifoliadas y la combinación de estas dos últimas), selvas (selvas bajas y selvas altas y medianas), manglares y otras asociaciones; en conjunto, estas zonas ocupan poco más de 66 millones de ha es decir el 48 % del área forestal. Mientras que las zonas no arboladas se distribuyen en más de la mitad de la superficie forestal con 72 millones de ha, de las cuales destaca el matorral xerófilo (formación forestal: las zonas áridas y semiáridas) y otras áreas forestales (Figura 18). Los ecosistemas más importantes en el ámbito forestal por sus recursos madereros son los bosques, la selva y el manglar, estos representan el 25, 22 y 1 % (Figura 19) del área de bosque respectivamente (CONAFOR, 2018).

El matorral xerófilo es relevante por la biodiversidad, número de endemismos y especies en estatus. Este ecosistema representa el 41 % de la superficie forestal y se encuentran principalmente comunidades de matorrales y plantas suculentas. El manglar y el bosque mesófilo son dos casos más de ecosistemas con gran biodiversidad, aunque juntos solo suman el 2 % del área forestal total, su conservación es necesaria para evitar perturbaciones graves, en especial el bosque mesófilo, las selvas bajas y selvas altas y medianas que solo conservan el 46, 42 y 24 % de la vegetación primaria, respectivamente (Figura 20) (CONAFOR, 2018).

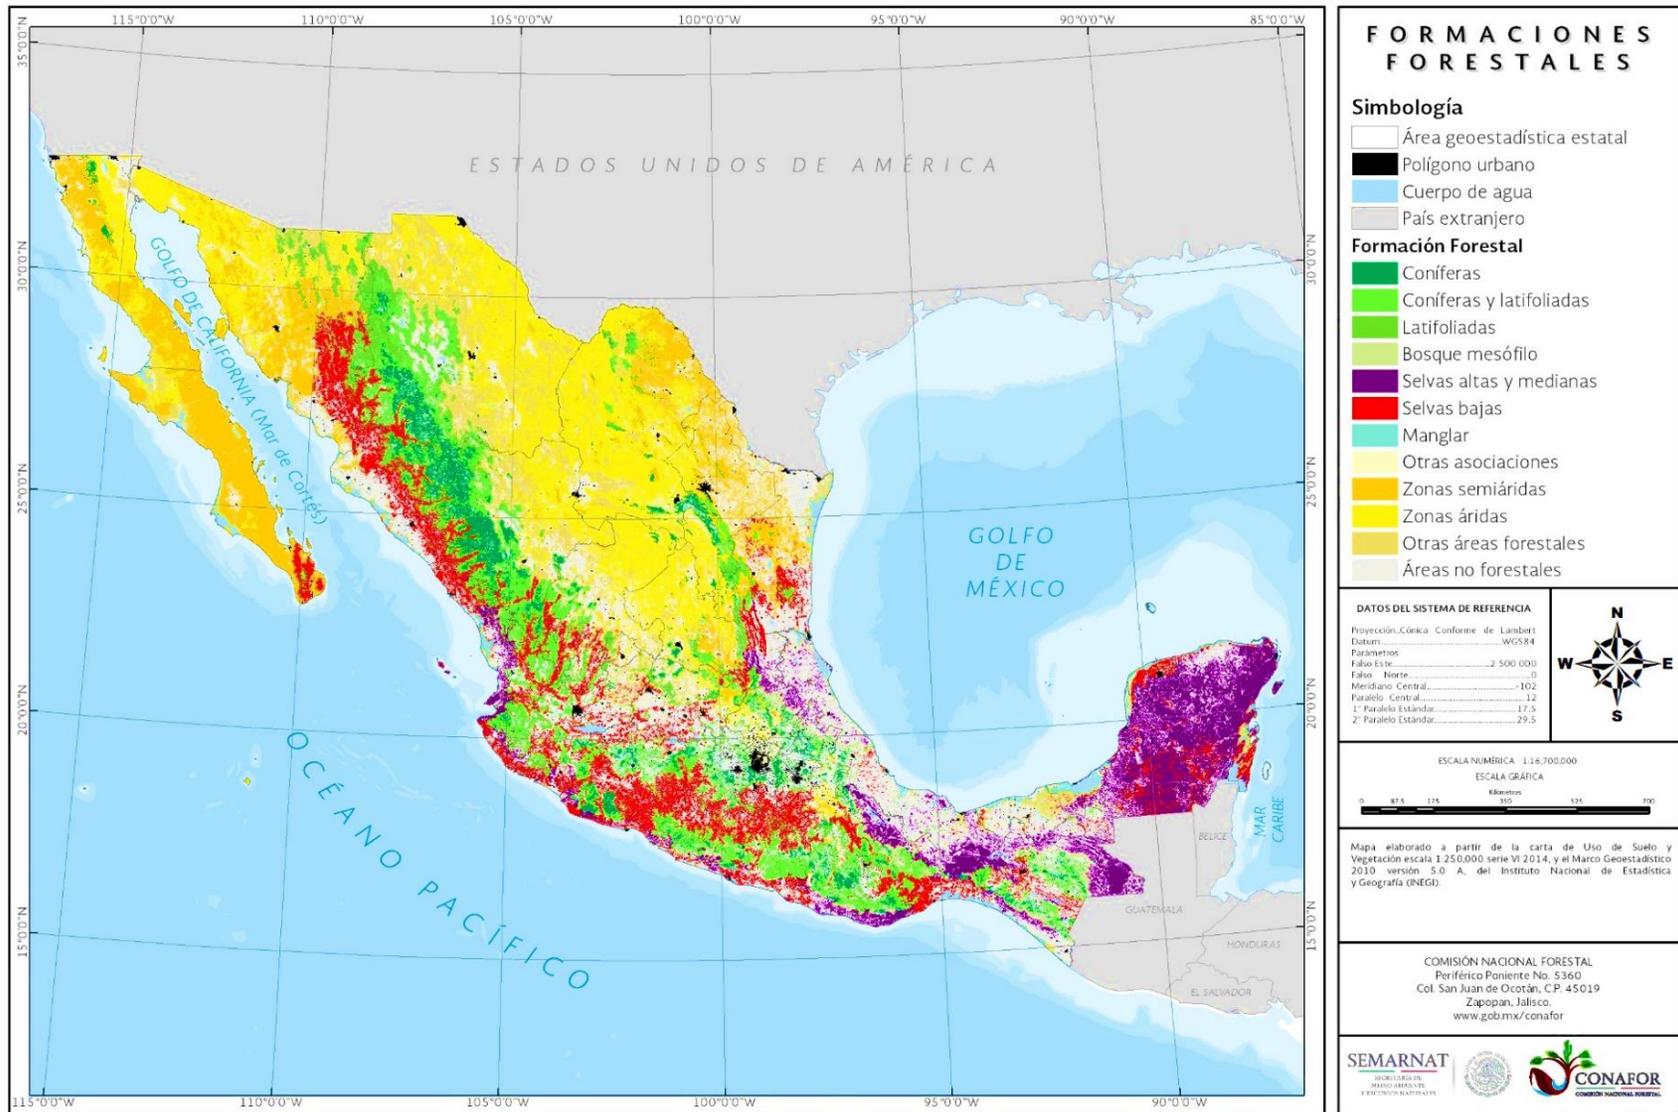


Figura 18. Distribución de las formaciones forestales en México. Fuente: Mapa descargado del Sistema Nacional de Información y Gestión Forestal (SNIGF), 2018.

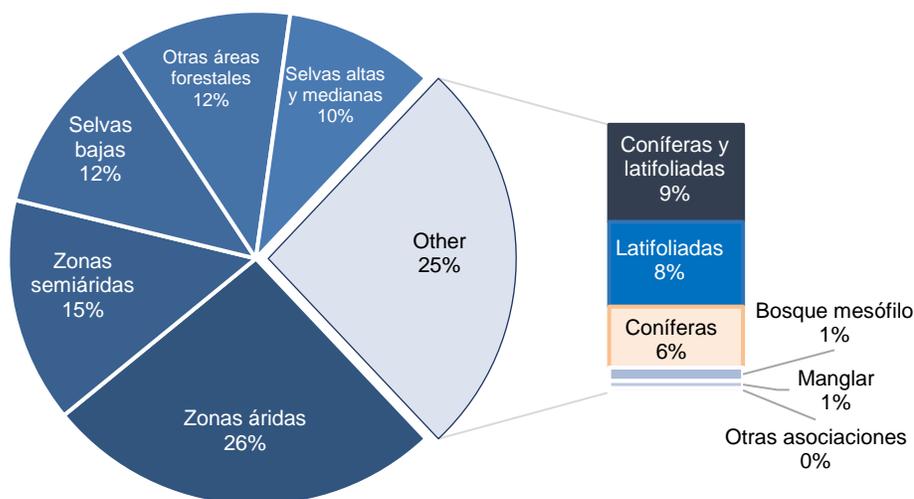


Figura 19. Superficie forestal de México representada por las principales formaciones forestales. Fuente: Elaboración propia con datos de CONAFOR, 2018.

Otras comunidades vegetales con una degradación mayor al 50 % son las selvas altas y medianas, seguidas de las selvas bajas. En los casos de las formaciones forestales latifoliadas, coníferas-latifoliadas y coníferas se tiene un riesgo moderado de alteración en la vegetación primaria, ya que se calculó cerca de 43, 37 y 36 % de vegetación secundaria respectivamente. Además, la formación forestal descrita como otras áreas forestales se compone de la vegetación herbácea de las fases sucesionales de la vegetación secundaria de todos los tipos de vegetación y representa el 12 % del área forestal (CONAFOR, 2018).

Para reconocer la causa de la degradación de las formaciones forestales de México se ha creó una clasificación nombrada como factores de daño, en el que se encuentran: los factores abióticos, bióticos y antropogénicos. Éstos son “el conjunto de elementos que producen o contribuyen al desarrollo del daño [al arbolado] como consecuencia de su variación o transformación”. Los factores abióticos y bióticos son los que afectan en un 64 % a los bosques de México, por el contrario, los daños causados por actividades antropogénicas solo sumaron un 5.5 % del total nacional (Figura 21). En los daños clasificados como “no reconocidos” no se pudo saber el factor o agente del daño (CONAFOR, 2018).

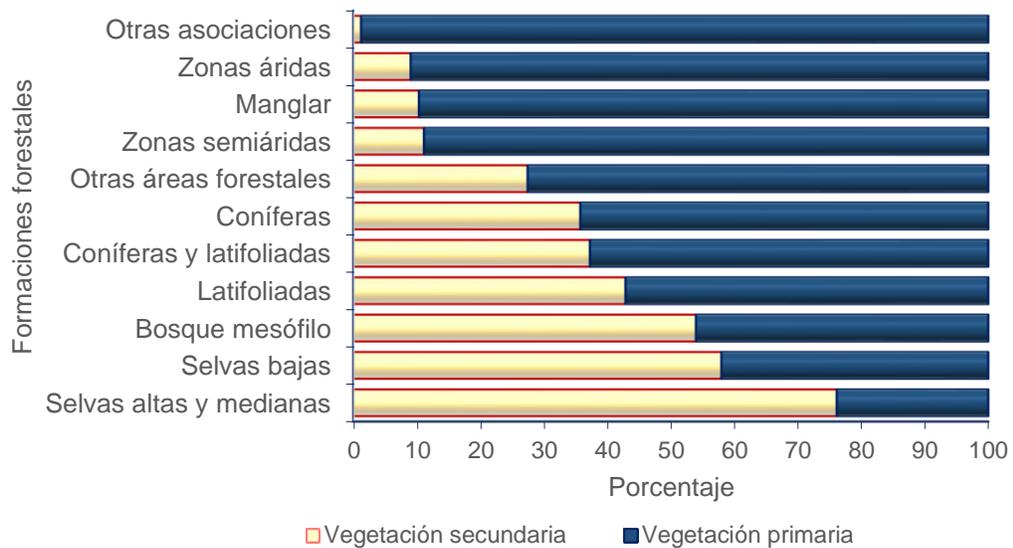


Figura 20. Porcentaje de degradación de las formaciones forestales de México. Fuente: Elaboración propia con datos de la CONAFOR, 2018.

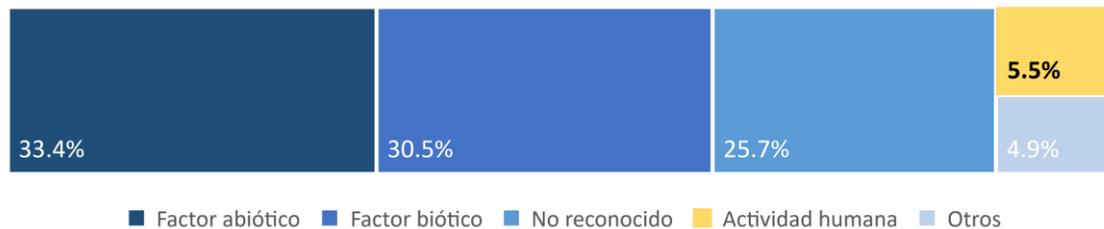


Figura 21. Factores de daño que afectan el desarrollo del arbolado en los bosques de México. Fuente: Elaboración propia con datos de CONAFOR, 2018.

Los agentes causales de daño son agrupados en los factores de daño y son los causantes específicos que provocan un perjuicio en la salud de los árboles (Figura 22). A nivel nacional, los tres principales agentes causales de daño son los incendios, insectos y vientos con un aproximado de 23, 18 y 10 % del total de bosques. En los bosques se presenta con mayor frecuencia los daños provocados por incendios y plagas, estos dos agentes suman el 50 % del daño en bosques. El viento afecta principalmente a las selvas altas-medianas, manglares y selvas bajas con 43, 27 y 19 % de incidencias provocadas por este daño (CONAFOR, 2018).

En el caso del matorral xerófilo el daño predominante es por insectos, aunque existe presencia de daños en el arbolado no se logró detectar el agente causal. La actividad humana afecta en mayor medida al bosque mesófilo, zonas áridas, bosque de coníferas, zonas semiáridas y al bosque de coníferas-latifoliadas, aunque no es representativo (CONAFOR, 2018).

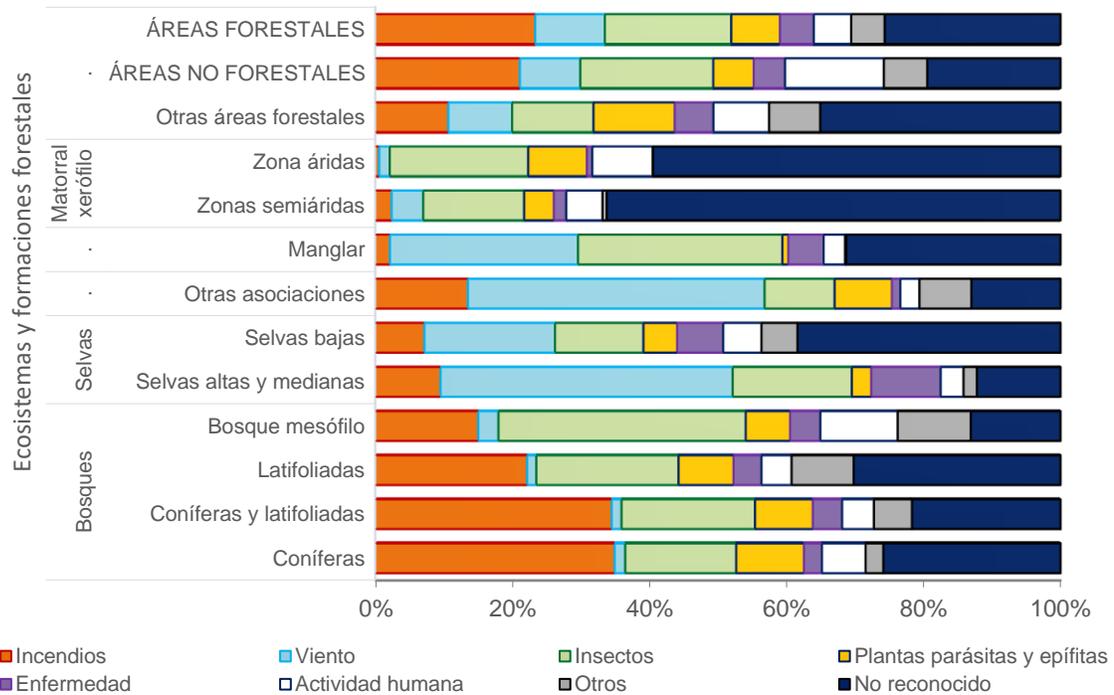


Figura 22. Proporción de los principales agentes causales de daño en la salud del arbolado por cada formación forestal de México. Fuente: Elaboración propia con datos de CONAFOR, 2018.

Los daños o cambios que afectan a los bosques de México también tienen otro origen, los cuales se clasifican con el nombre de impactos ambientales y se definen como: “el efecto que causa una actividad o evento, que conlleva una modificación visible al medio natural, tanto positivo como negativo, dependiendo del efecto que se produce entre esta intervención”. Dentro del INFyS se registró 20 mil conglomerados que son la base para estudiar el efecto de los impactos ambientales de los recursos: agua, suelo y vegetación. En este caso se describe en la figura 23 la proporción de las causas de impacto ambiental de la vegetación forestal (CONAFOR, 2018).

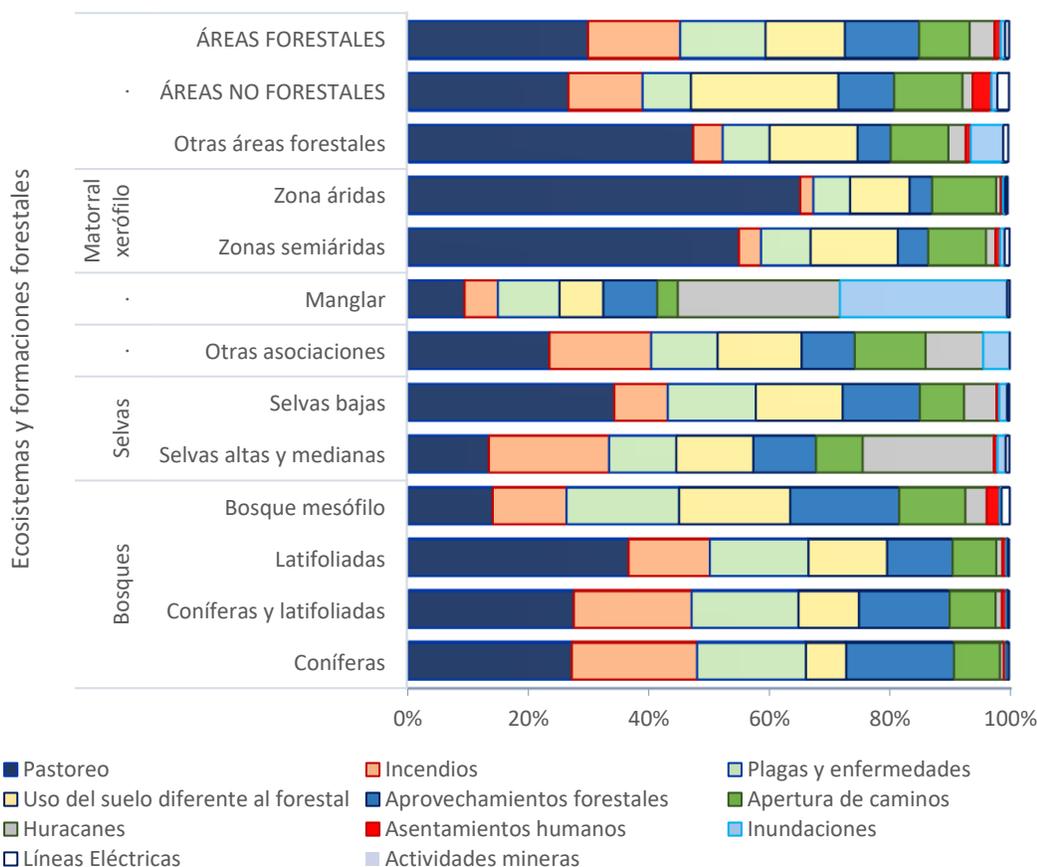


Figura 23. Porcentaje de las principales causas de impacto ambiental por cada una de las formaciones forestales de México. Fuente: Elaboración propia con datos de CONAFOR, 2018.

Los factores de impacto ambiental de mayor incidencia son causados principalmente por las actividades humanas, seguido de los factores abióticos y bióticos con un 85, 43 y 32 % de la muestra, respectivamente. Los impactos ambientales están asociados con más de una actividad o evento, por lo que se registraron más de una causa en el mismo sitio y se obtuvieron esos resultados (CONAFOR, 2018).

En específico, el pastoreo fue la principal causa de impacto ambiental en los conglomerados evaluados, con un porcentaje de 68 %. Las causas de incidencia media son: los incendios, plagas y enfermedades, uso del suelo diferente al forestal, aprovechamientos forestales y apertura de caminos con un porcentaje de 35, 32, 30, 28 y 19 % respectivamente (CONAFOR, 2018).

En los bosques de México se debe de implementar un plan de MFS manejo forestal para disminuir el efecto ocasionado por las siguientes causas de impacto ambiental: pastoreo, incendios, plagas y enfermedades, uso del suelo diferente al forestal, aprovechamientos forestales y en menor medida la apertura de caminos; estos impactos superan el 90 % de incidencias. En las selvas se deben considerar las mismas causas que en los bosques, pero agregando planes de manejo para reducir el impacto de los huracanes, principalmente en las selvas altas y medianas. En los manglares los huracanes y las inundaciones son los impactos ambientales que suman más de la mitad de los daños observados (CONAFOR, 2018).

Por el contrario, en los matorrales xerófilos el evento que causa un cambio mayor al 50 % es el pastoreo, seguido del uso del suelo diferente al forestal, la apertura de caminos y las plagas y enfermedades, estas últimas causas superan el 40 % respecto al número de conglomerados con registro de impacto ambiental (CONAFOR, 2018).

Los problemas descritos y relacionados con los impactos ambientales reducen el área forestal con el paso de los años. Para visualizar la dinámica de cambios de los bosques en la figura 24 se tiene el registro de la variación en la superficie arbolada, no arbolada y total del sector forestal para el periodo 1993-2014. Los cambios en el tiempo del área forestal se basan en la cartografía del INEGI (2017), donde las Cartas del Uso del Suelo y Vegetación presentan esta información como series cartográficas, con los siguientes años de referencia: Serie II-1993, Serie III-2002, Serie IV-2007, Serie V-2011 y Serie VI-2014 (CONAFOR, 2018).

La estimación de la información, referida a los cambios del área forestal, es útil para ser comparada en las diferentes series descritas, porque el proceso metodológico y el sistema de clasificación de la vegetación no han sufrido grandes cambios, aunque las técnicas empleadas para la generación sí se han transformados por los avances tecnológicos (CONAFOR, 2018). Los resultados de comparar la superficie forestal de México estimada en la serie II-1993 con la

serie VI-2014 son los siguientes: se ha perdido cerca de 6.4 millones de ha, es decir un 4.4 % del total de superficie; la tasa de cambio anual para el periodo de estudio es de -0.22 %, la cual se calculó a partir de la pérdida neta de la superficie forestal: 303,920 ha/año (CONAFOR, 2018).

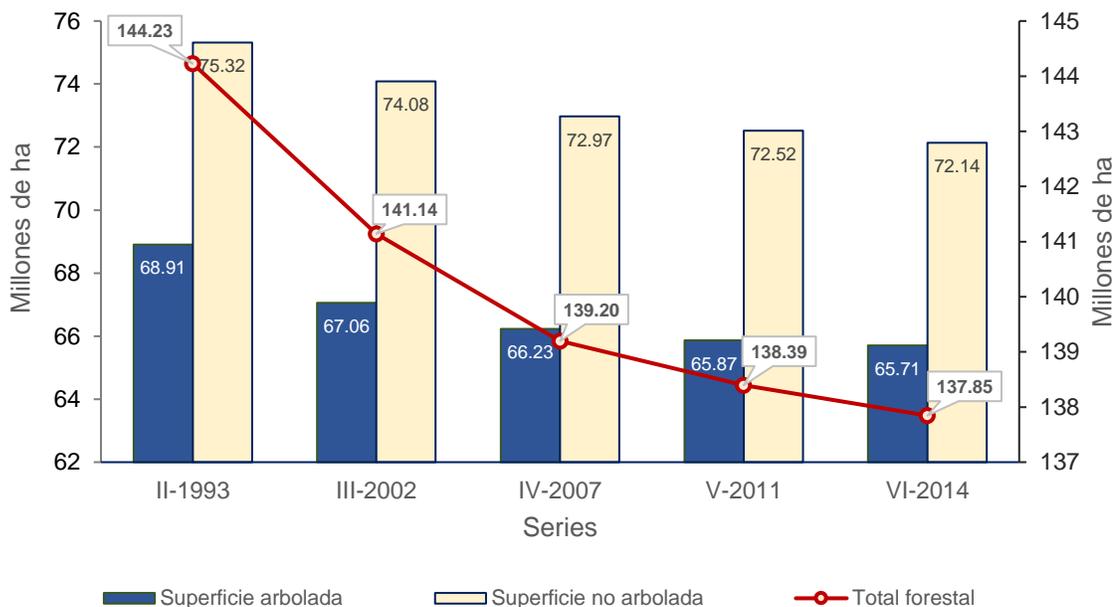


Figura 24. Cambios en la superficie forestal total, arbolada y no arbolada para el periodo 1993-2014. Fuente: Elaboración propia con datos de CONAFOR, 2018.

El total de pérdida de superficie forestal descrita se debe a que se ha reducido en aproximadamente 3.2 millones de ha en la superficie arbolada y no arbolada. En específico, los ecosistemas en los que se calculó una disminución relevante, al restar el valor de la superficie del 2014 con la que se tenía en 1993, son: las selvas (Figura 25), matorral xerófilo y otras áreas forestales (Figura 26) con cerca de 3, 2 y 1 millones de ha respectivamente. Los ecosistemas de menor impacto en la superficie fueron los bosques (289 mil ha) y las otras asociaciones (121 mil ha). Por el contrario, en los manglares se tuvo un aumento de 25 mil ha de 1993 al 2007, pero disminuyó su superficie del año 2007 al 2014 en 6 mil ha (CONAFOR, 2018).

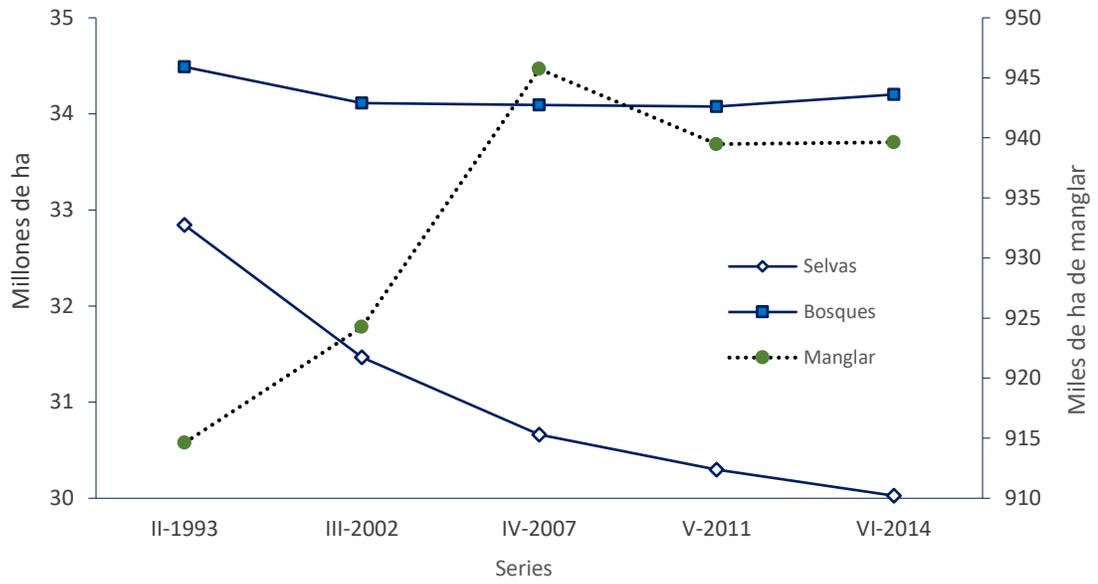


Figura 25. Variación en la superficie de las selvas, bosques y manglares de México en el periodo 1993-2014. Fuente: Elaboración propia con datos de la CONAFOR, 2018.

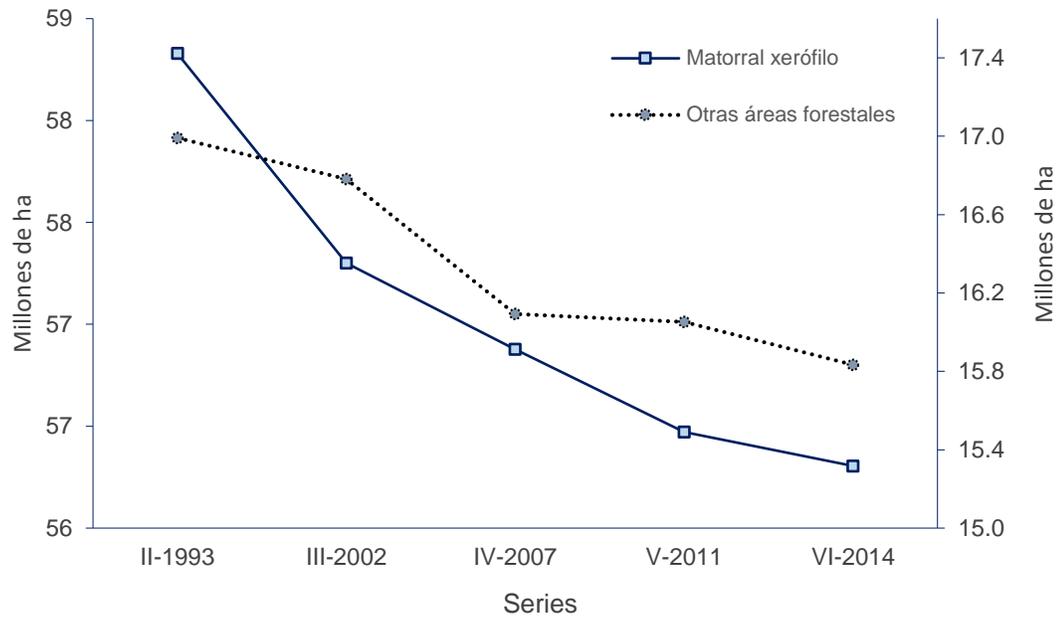


Figura 26. Variación en la superficie de las selvas, bosques y manglares de México en el periodo 1993-2014. Fuente: Elaboración propia con datos de la CONAFOR, 2018.

Para crear o modificar las políticas ambientales enfocadas al sector forestal se debe de considerar los diferentes criterios descritos en los dos ciclos de muestreo concluidos del INFyS, de los periodos 2004-2009 y 2009-2014 y, con ello, desarrollar planes de MFS para mejorar la producción maderable y no maderable del país, siempre con un enfoque de conservación (CONAFOR, 2018).

La producción forestal es uno de los indicadores descrito en el Anuario Estadístico de la Producción Forestal 2016 elaborado por la Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT, 2016). Este anuario es el más reciente y presenta, además, un análisis de la información de los últimos 5 años sobre el precio, valor y comercio internacional de los géneros y productos forestales maderables y no maderables de México. También se desglosan datos de aprovechamiento, sanidad, industria, consumo aparente, balanza comercial y producto interno bruto de este sector.

La categoría denominada como productos maderables se refiere a los materiales leñosos y se divide en dos tipos: 1) por género y/o grupo: pino, oyamel, otras coníferas, encino, otras latifoliadas, preciosas y comunes tropicales; 2) por producto: escuadría, celulosa, chapa y triplay, leña, carbón, durmientes y postes-pilotes-morillos. En el caso de los productos no maderables, que en su mayoría son productos de recolección, se agrupan en: resinas, fibras, gomas, ceras, rizomas, otros (hongos, frutos, semillas, tallos, musgo, heno y otros) y tierra de monte (SEMARNAT, 2016).

Para el caso del promedio anual de la producción forestal maderable de México, en el periodo de 1986 a 2017, se calculó en 7.2 millones de metros cúbicos de madera en rollo (m^3r). En los años en los que la producción forestal maderable obtuvo los valores más altos fue en 1987, 2000 y 1988 con 9.8, 9.4 y 9.3 millones de m^3r en cada caso (Figura 27), mientras que del 2009 al 2015 se presentó la menor producción con un promedio anual de 5.8 millones de m^3r , una diferencia de poco más de 4 millones entre el valor máximo y el promedio de los valores mínimos de producción (SEMARNAT, 2019a).

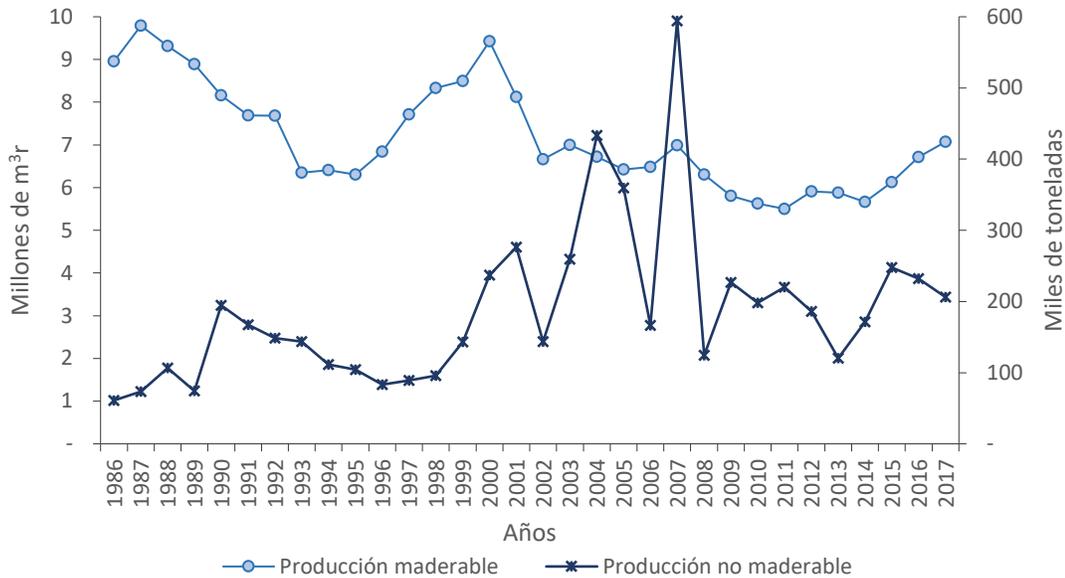


Figura 27. Producción forestal maderable y no maderable de México del periodo: 1986-2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019a.

Por su parte, la producción forestal maderable acumulada de todo el país en el periodo 1990-2017 se puede observar en la figura 28, con la cual se calcula que poco más del 73 % de la producción nacional se generó en solo cinco estados: Durango (28 %), Chihuahua (19 %), Michoacán (12 %), Oaxaca (7 %) y Jalisco (6 %), aunque es preciso destacar que los tres primeros estados suman el 60 % del total por lo que su producción ha sido relevante. El resto de los estados presentaron un porcentaje menor al 1 % del total nacional, lo cual se sumó y se presenta en la categoría “otros” de la misma gráfica (SEMARNAT, 2019b).

Además, para el último año de muestreo 2017 los estados que aumentaron su producción fueron Tabasco y Veracruz lo que les hizo subir a los puestos tres y cuatro del top cinco de los estados con mayor producción en ese año de estudio, con 521, 546 y 441,546 m³r, por lo que generaron el 7 y 6 % del total nacional, seguido de Michoacán con el 6 % (Figura 29). Tabasco no ha sido de los estados con una producción maderable alta, su valor acumulado histórico en este rubro se calculó en 0.7 %. Los dos primeros lugares los siguen ocupando Durango (32 %) y Chihuahua (16 %) con 2.3 y 1.1 millones de metros cúbicos de productos maderables (SEMARNAT, 2019b).

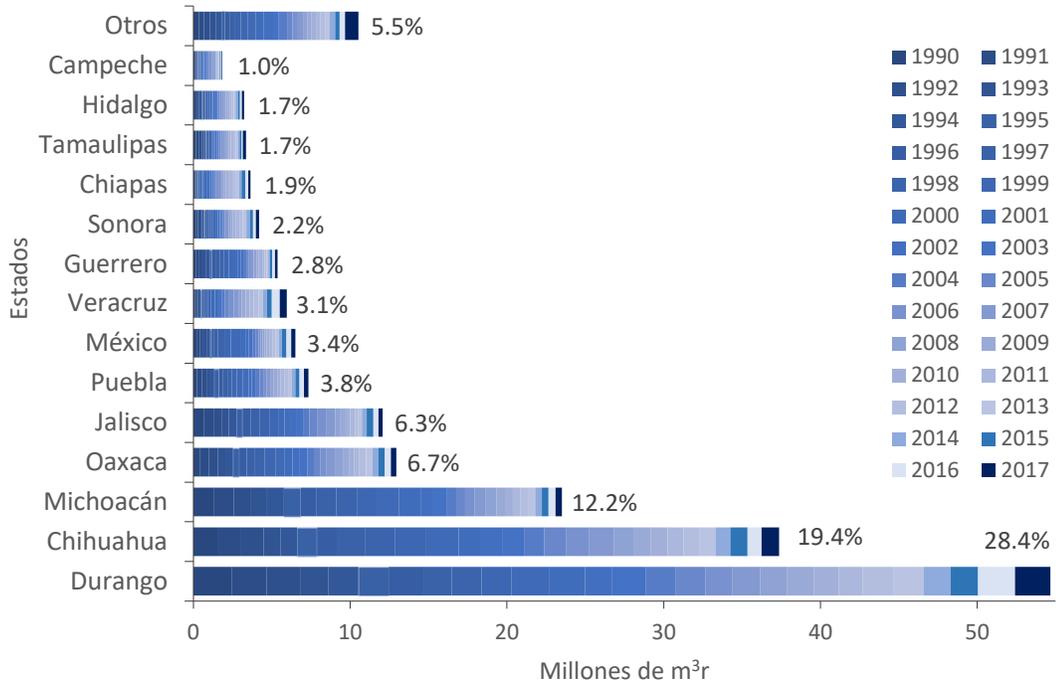


Figura 28. Comparación de la producción forestal maderable acumulada entre los estados de México en el periodo 1990-2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.

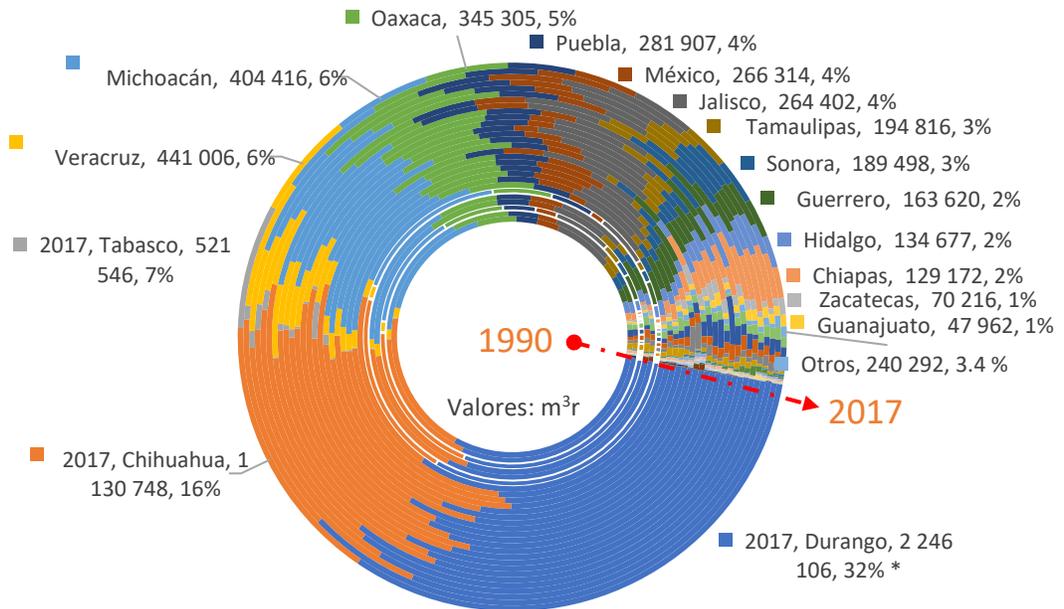


Figura 29. Producción forestal maderable por entidad federativa para el periodo 1990-2017. *Los valores mostrados están ordenados en orden decreciente respecto a los datos del año 2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.

La especie forestal que más se produce en México es el pino (conífera) con un promedio anual de 5.4 millones de m³r, en el periodo 1990-2019, lo cual ha representado un 80 % del total nacional (Figura 30). En el año más reciente (2017), de esta especie se produjo cerca de 5 millones de m³r, seguido del encino (latifoliadas), maderas comunes (tropicales), oyamel (coníferas) y maderas preciosas (tropicales) con 677, 389, 207 y 13 mil m³r respectivamente, estos valores representaron, para cada caso, el 70.6, 9.6, 5.5, 2.9 y 0.2 % del total en ese año; otras latifoliadas y coníferas sumaron el 11.2 % (SEMARNAT, 2019b).

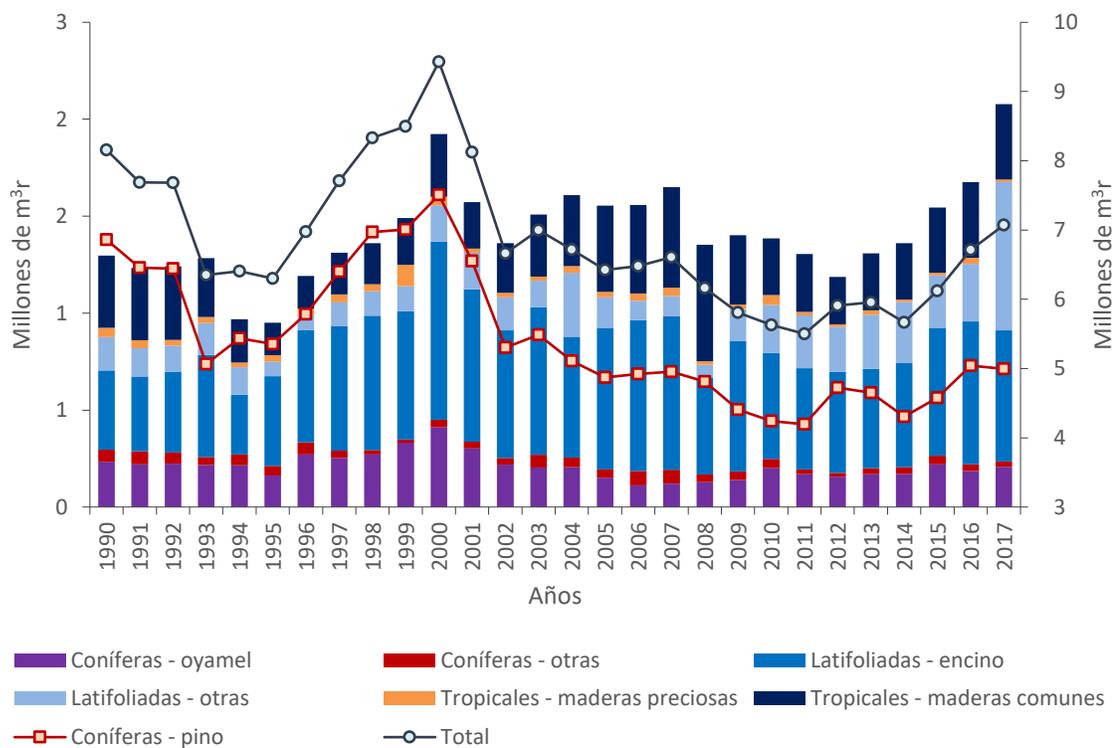


Figura 30. Producción forestal maderable de México por especie para el periodo 1990-2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.

El destino de la producción maderable en el año 2016 se dio principalmente para madera de aserrío (escuadría y durmientes) y combustibles (leña y carbón) con 5 y 0.63 millones de m³r, el equivalente al 84.3 % del total nacional (Figura 32). El resto de la producción, el 15.7 %, se designó para celulosa, chapa y triplay, postes, pilotes y morillos, cerca de 1.1 millones de m³r (SEMARNAT, 2016).

Respecto a la producción forestal nacional no maderable se encontró que durante el periodo de 1986-2017 se han producido cerca de 6 millones de toneladas (t), con una media de 188 mil t anuales (Figura 31). En los años de 2007, 2004, 2005 y 2001 se obtuvieron los valores más altos en la producción de productos forestales no maderables, con 594, 433, 359 y 276 mil t respectivamente. Al inicio del periodo se registró la menor producción, principalmente en los años 1986, 1987 y 1989 con 61, 73 y 74 mil t para cada uno (SEMARNAT, 2019a).

Además, la mayor producción acumulada se obtuvo principalmente en el Estado de México (21 %), Ciudad de México (15 %), Sonora (13 %), Morelos (12.6 %) y Michoacán (11.6 %), los cuales suman poco más del 73 % del total de productos forestales no maderables (Figura 32). El Estado de México y la Ciudad de México han destacado por obtener la mitad de la producción acumulada, con 1.2 y 0.9 millones de t en el periodo de estudio (SEMARNAT, 2019b).

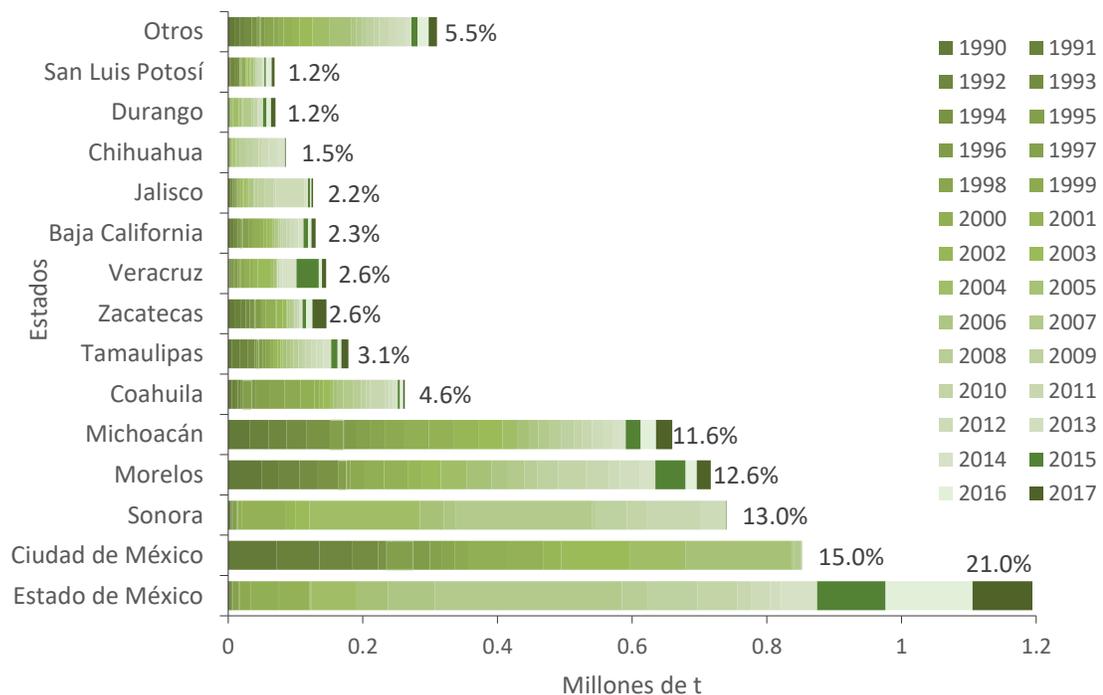


Figura 31. Producción forestal no maderable acumulada de los estados, periodo 1990-2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.

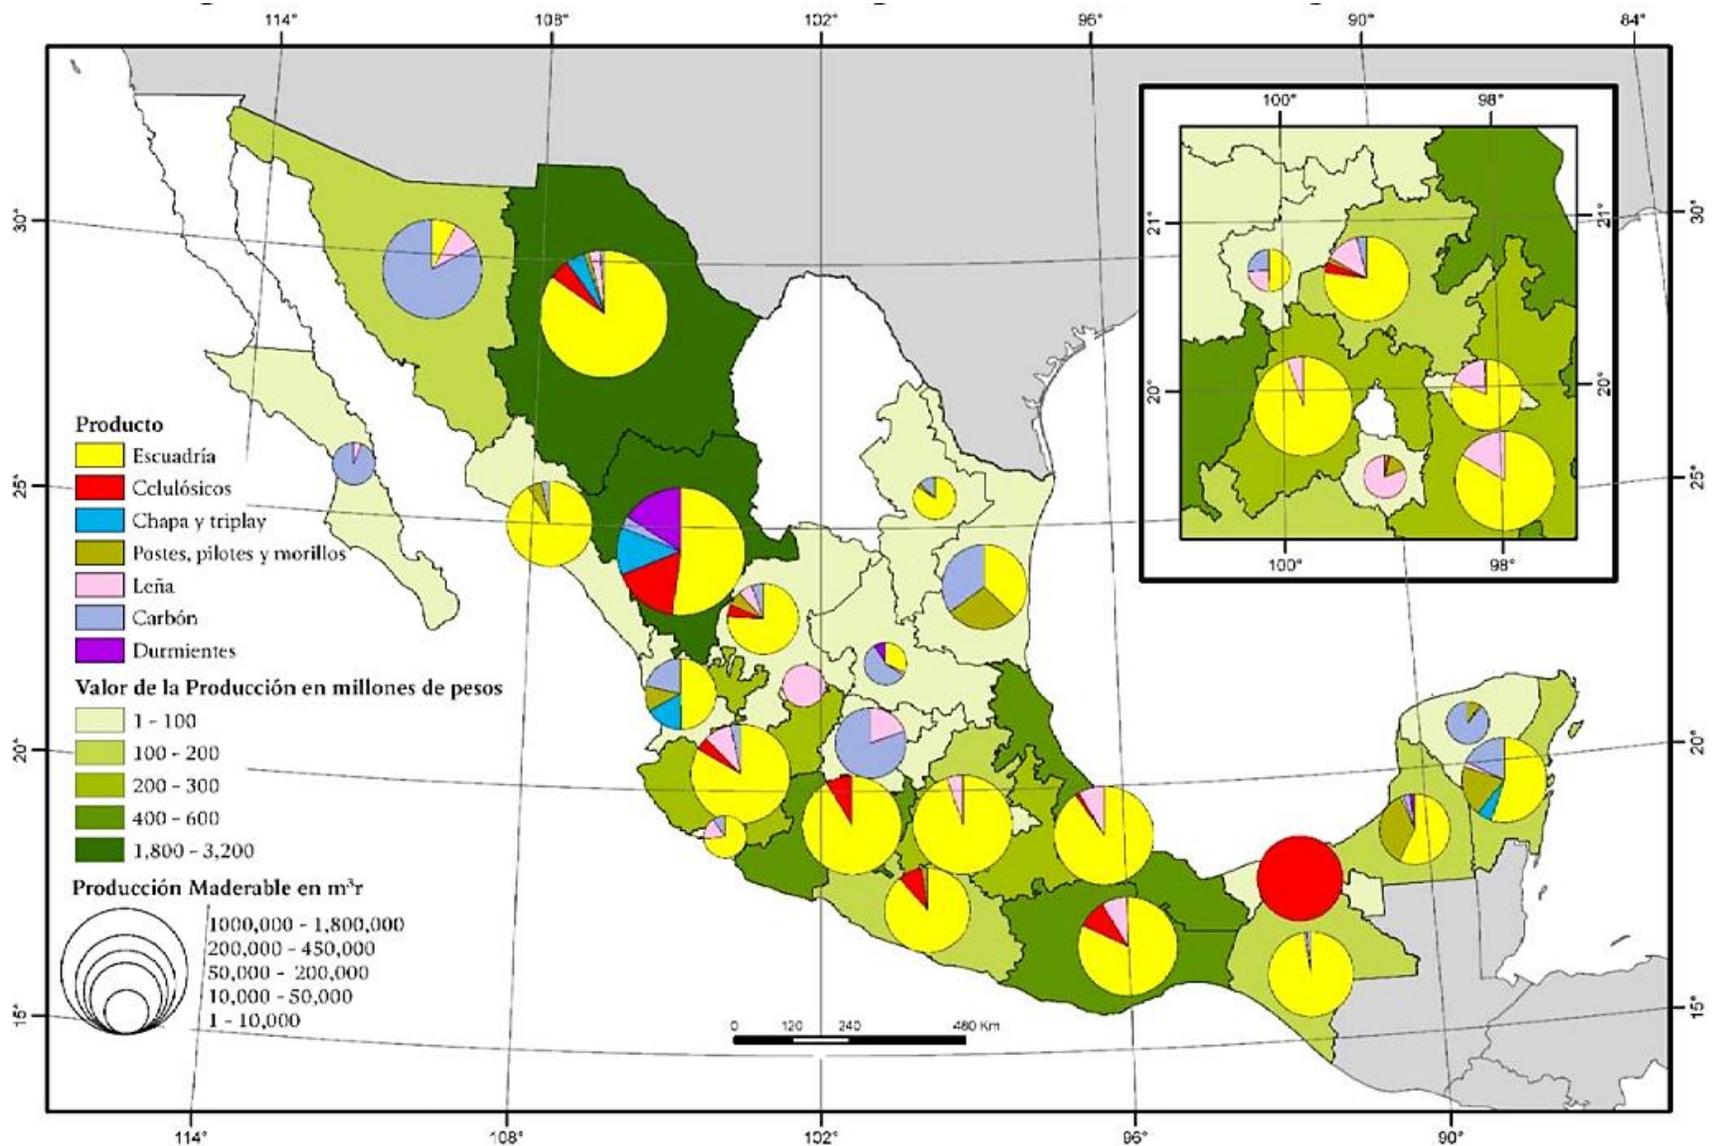


Figura 32. Producción forestal maderable de México por producto, valor y volumen para el año 2016. Fuente: Tomado de SEMARNAT, 2016.

Para el año 2017 el Estado de México, Michoacán, Morelos, Zacatecas y Tamaulipas fueron los que repuntaron en la producción de los productos no maderables con 89, 24, 21, 21 y 11 mil t respectivamente, juntos contribuyeron con poco más de 80 % del total nacional (Figura 33). La Ciudad de México dejó de producir drásticamente este tipo de productos a partir del año 2006, con 161 mil t menos que el año anterior, para el año 2010 los valores reportados fueron cero t; el mismo caso se presentó para el estado de sonora que en su periodo más productivo, 2000-2012, logró una producción promedio de 56 mil t anuales y después del 2012 al 2017 alcanzó un promedio de 20 t (SEMARNAT, 2019b).

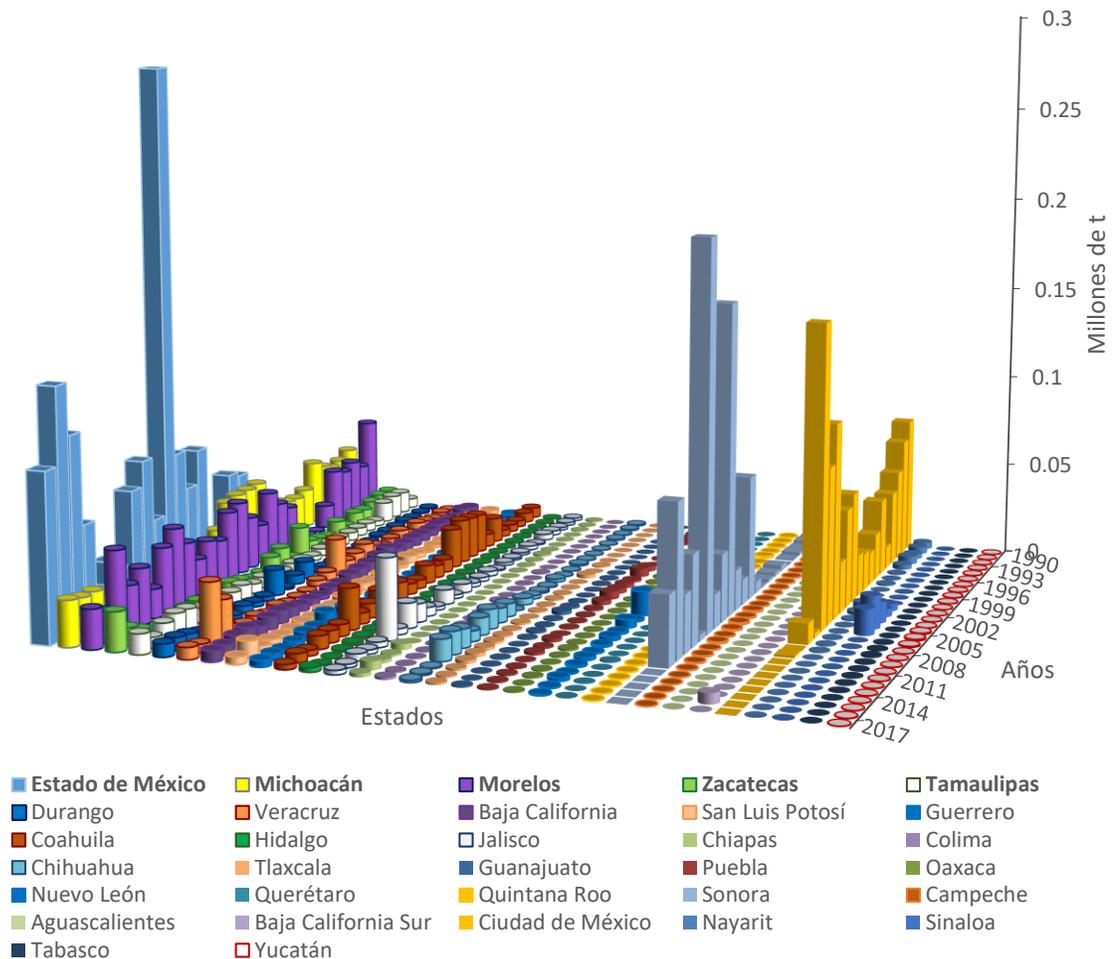


Figura 33. Producción forestal no maderable por entidad federativa para el periodo 1990-2017. * Los valores mostrados están ordenados en orden decreciente de izquierda a derecha, respecto a los datos del año 2017. Fuente: Elaboración propia con datos de SEMARNAT, 2019b.

La producción y las existencias de madera en rollo dentro de la vegetación forestal están relacionadas, por lo que se observa en la figura 34 una reducción del 24 % de la madera en rollo perteneciente a los bosques, es decir, cerca de 575 millones de metros cúbicos menos al comparar los datos del periodo 200-2009 (2,424 millones de m³) y 2009-2014 (1.849 millones de m³). Por el contrario, en las selvas se aumentó en 207 millones de m³, poco más del 14 % de las existencias originales para el mismo periodo: 1,463 y 1671 millones de m³r (SEMARNAT, 2019a).

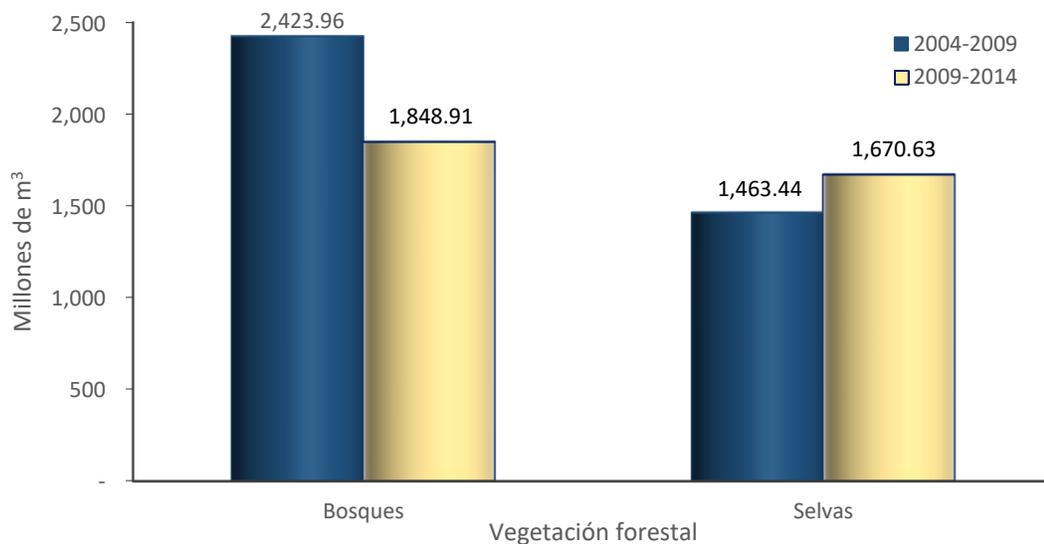


Figura 34. Existencias de madera en rollo en bosques y selvas. Fuente: Elaboración propia con datos de SEMARNAT, 2019a.

Otro indicador que describe la situación del sector forestal es el producto interno bruto (PIB), el cual se ha calculado en 18,568 millones de pesos a valores de 2013, en el periodo 1993 a 2019 (el 2019 se estimó con los primeros 3 valores trimestrales de ese año) y los valores mayores se obtuvieron en los años 2000, 2018, 2017, 2001 y 1999 con 21, 21, 21, 20 y 20 mil millones de pesos (Figura 35). Los valores más bajos se tienen registrados en los primeros dos años del periodo de estudio: 1995 (16.4 x10⁹) y 1993 (17.1 x10⁹), posterior a estos años, en el periodo de 2009 a 2014, el sector forestal de México estuvo en recesión respecto al PIB, con un promedio anual de 17.7 mil millones (Instituto Nacional de Estadística y Geografía [INEGI], 2019).

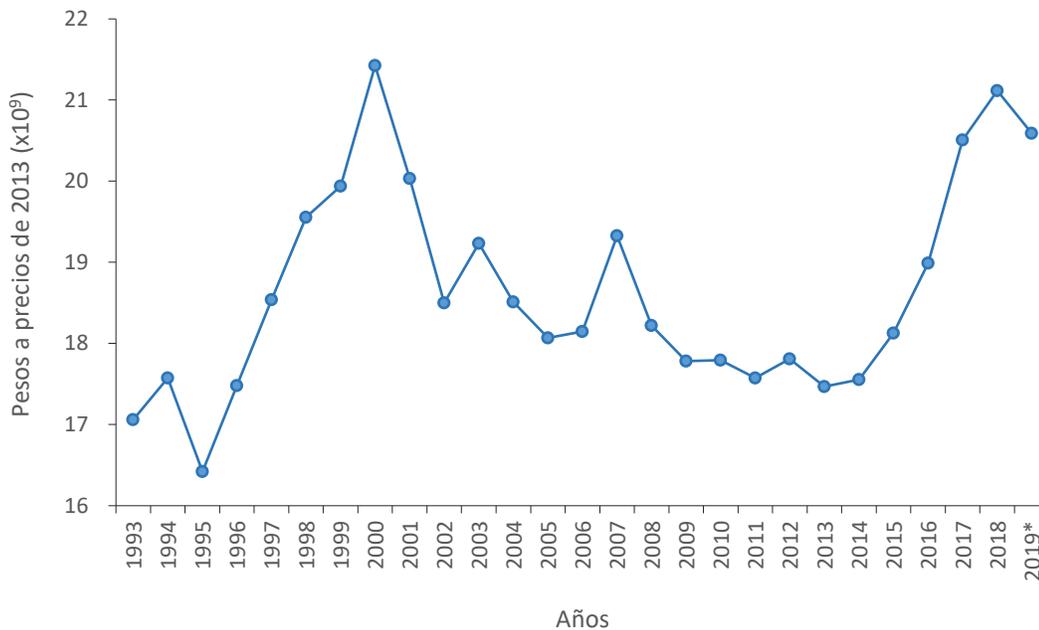


Figura 35. PIB del aprovechamiento forestal de México para el periodo 1993-2019. *2019: valor preliminar estimado con la media de 3 trimestres. Fuente: Elaboración propia con datos de INEGI, 2019.

3.5 Conclusiones

En este trabajo se describió y analizó las bases de datos del sector forestal, lo cual permitió alcanzar el objetivo planteado y generar un informe general del estado actual de los bosques de México y el mundo.

Se concluye que, a nivel nacional y mundial, es indispensable optar por MFS, debido a que los bosques están siendo degradados por las actividades antropogénicas y porque proporcionan múltiples beneficios para mejorar los medios de subsistencia de toda la población humana, como son los productos maderables y no maderables, además de ser parte importante en los ciclos del aire y el agua, y son el medio para la conservación de la biodiversidad.

Respecto al éxito del MFS, se requieren de políticas públicas que desarrollen un sector forestal estable, eficiente y que sea económicamente aceptable.

Además, se observó que los países con un MFS se caracterizan por beneficiar a los productores del ámbito forestal, dado que se aumentan las ganancias económicas y mejoran los servicios ambientales. Por lo cual, es vital que se implanten con eficiencia los MFS en México.

El futuro del análisis de las bases de datos del sector forestal estará determinado por los avances en la tecnología y los métodos para estimar, evaluar, generar y analizar gran cantidad de información nueva y de otras variables que pueden ser descritas, como: los incendios, el cambio climático, las plantas invasoras, las plagas y enfermedades. Por lo tanto, se requieren de más estudios sistemáticos que permitan actualizar la información periódica y, con ello, generar informes con el panorama más actual de los bosques de México y el mundo.

3.6 Literatura citada

Comisión Nacional Forestal. (2012). *Inventario Nacional Forestal y de Suelos: Informe de Resultados 2004-2009* (Primera ed.). <https://snigf.cnf.gob.mx/resultados-2004-2009/>

Comisión Nacional Forestal. (2018). *Inventario Nacional Forestal y de Suelos: Informe de Resultados 2009-2014* (Primera ed.). <https://snigf.cnf.gob.mx/resultados-2009-2014/>

Dinerstein, E., Olson, D., Joshi, A., Vynne, C., Burgess, N. D., Wikramanayake, E., Hahn, N., Palminteri, S., Hedao, P., Noss, R., Hansen, M., Locke, H., Ellis, E. C., Jones, B., Barber, C. V., Hayes, R., Kormos, C., Martin, V., Crist, E., ... Hansen, M. (2017). An ecoregion-based approach to protecting half the terrestrial realm. *BioScience*, 67(6), 534-545. <https://doi.org/10.1093/biosci/bix014>

Dinerstein, E., Vynne, C., Sala, E., Joshi, A. R., Fernando, S., Lovejoy, T. E., Mayorga, J., Olson, D., Asner, G. P., Baillie, J. E. M., Burgess, N. D., Burkart, K., Noss, R. F., Zhang, Y. P., Baccini, A., Birch, T., Hahn, N., Joppa, L. N., & E. Wikramanayake (2019). A global deal for nature: guiding principles, milestones, and targets. *Science advances*, 5(4), artículo eaaw2869. <https://doi.org/10.1126/sciadv.aaw2869>

Ferreira, L. N., Vega-Oliveros, D. A., Zhao, L., Cardoso, M. F., & Macau, E. E. (2020). Global Fire Season Severity Analysis and Forecasting. *Computers & Geosciences* 134, artículo 104339. <https://doi.org/10.1016/j.cageo.2019.104339>

Gryazkin, A., Bepalova, V., Samsonova, I., Belyaeva, N., & Belyaev, V. (2019). Potential reserves and development of non-wood forest resources. In *IOP*

Conference Series: Earth and Environmental Science, 316(1), artículo 12007. <https://doi.org/10.1088/1755-1315/316/1/012007>

- Instituto Nacional de Estadística y Geografía. (2019). *Banco de Información Económica (BIE): series históricas actualizables con información económica de México*. Recuperado el 30 de noviembre de 2019, de <https://www.inegi.org.mx/app/indicadores/?tm=0#divFV494105>
- Jacobson, A. P., Riggio, J., Tait, A. M., & Baillie, J. E. (2019). Global areas of low human impact ('Low impact Areas') and fragmentation of the natural world. *Scientific reports*, 9(1), artículo 14179. <https://doi.org/10.1038/s41598-019-50558-6>
- Linser, S., Wolfslehner, B., Bridge, S., Gritten, D., Johnson, S., Payn, T., Prins, K., Raši, R., & Robertson, G. (2018). 25 Years of Criteria and Indicators for Sustainable Forest Management: How Intergovernmental C&I Processes Have Made a Difference. *Forests*, 9(9), artículo 578. <https://doi.org/10.3390/f9090578>
- Maron, M., Simmonds, J. S., & Watson, J. E. (2018). Bold nature retention targets are essential for the global environment agenda. *Nature ecology & evolution*, 2(8), 1194-1195. <https://doi.org/10.1038/s41559-018-0595-2>
- Menezes-Silva, P. E., Loram-Lourenço, L., Alves, R. D. F. B., Sousa, L. F., Almeida, S. E. D. S., & Farnese, F. S. (2019). Different ways to die in a changing world: Consequences of climate change for tree species performance and survival through an ecophysiological perspective. *Ecology and evolution*, 9(20), 11979-11999. <https://doi.org/10.1002/ece3.5663>
- Mondal, B., Saha, A. K., & Roy, A. (2019). Mapping mangroves using LISS-IV and Hyperion data in part of the Indian Sundarban. *International Journal of Remote Sensing*, 40(24), 9380-9400. <https://doi.org/10.1080/01431161.2019.1630784>
- Newbold, T., Hudson, L. N., Hill, S. L., Contu, S., Lysenko, I., Senior, R. A., Börger, L., Bennett, D. J., Choimes, A., Collen, B., Day, J., Palma, A. D., Díaz, S., Echeverria-Londoño, J., Edgar, M. J., Feldman, A., Garon, M., Harrison, M. L. K., Alhusseini, T., ... & Day, J. (2015). Global effects of land use on local terrestrial biodiversity. *Nature*, 520(7545), 45-50. <https://doi.org/10.1038/nature14324>
- Olofsson, P., Arévalo, P., Espejo, A. B., Green, C., Lindquist, E., McRoberts, R. E., & Sanz, M. J. (2020). Mitigating the effects of omission errors on area and area change estimates. *Remote Sensing of Environment*, 236, artículo 111492. <https://doi.org/10.1016/j.rse.2019.111492>
- Organización de las Naciones Unidas. (2019). *Population Division World Population Prospects 2019*. Departamento de Asuntos Económicos y Sociales, División de Población. Recuperado el 1 de enero de 2020, de <https://population.un.org/wpp/DataQuery/>

- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2016). Evaluación de los recursos forestales mundiales 2015: ¿Cómo están cambiando los bosques del mundo? (Segunda ed.). <http://www.fao.org/3/a-i4793s.pdf>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2018). *1948-2018 Seventy years of FAO's Global Forest Resources Assessment: Historical overview and future prospects*. <http://www.fao.org/3/l8227EN/i8227en.pdf>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2019a). FAOSTAT [Data set]. Recuperado el 30 de febrero de 2020, de <http://www.fao.org/faostat/es/#data>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2019b, 12 de septiembre). *Sustainable forest management*. Recuperado el 28 de noviembre de 2019, de <http://www.fao.org/forestry/sfm/en/>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2020a, mayo). Evaluación de los recursos forestales mundiales. Recuperado el 18 de mayo del 2020, de <http://www.fao.org/forest-resources-assessment/es/>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2020b). Evaluación de los recursos forestales mundiales 2020: Principales resultados [pdf]. Recuperado el 9 de mayo del 2020, de <http://www.fao.org/3/ca8753es/CA8753ES.pdf>
- Secretaría de Medio Ambiente y Recursos Naturales (2016). *Anuario Estadístico de la Producción Forestal 2016* (Primera ed.). <https://www.gob.mx/cms/uploads/attachment/file/282951/2016.pdf>
- Secretaría de Medio Ambiente y Recursos Naturales (2019a). *Indicadores básicos del desempeño ambiental: Recursos forestales nacionales*. Recuperado el 25 de noviembre de 2019, de <https://datos.gob.mx/busca/dataset/indicadores-basicos-del-desempeno-ambiental--recursos-forestales>
- Secretaría de Medio Ambiente y Recursos Naturales (2019b). *Recursos forestales: Indicador básico 7-2*. Recuperado el 25 de noviembre de 2019, de https://apps1.semarnat.gob.mx:8443/dgeia/indicadores17/conjuntob/indicador/07_forestales/7_2.html
- Siry, J. P., Cabbage, F. W., Potter, K. M., & McGinley, K. (2018). Current perspectives on sustainable forest management: North America. *Current Forestry Reports*, 4(3), 138-149. <https://doi.org/10.1007/s40725-018-0079-2>
- Sistema Nacional de Información y Gestión Forestal. (2018). *Resultados 2009-2014*. Recuperado el 25 de noviembre de 2019, de <https://snigf.cnf.gob.mx/resultados-2009-2014/>

- Watson, J. E., & Venter, O. (2017). Ecology: a global plan for nature conservation. *Nature*, 550(7674), 48-49. <https://doi.org/10.1038/nature24144>
- Wear, D. N., & Greis, J. G. (2013). *The southern forest futures project: Technical report*. (Gen. Tech. Rep. SRS-GTR-178). Asheville, NC: USDA-Forest Service, Southern Research Station. https://www.srs.fs.fed.us/pubs/gtr/gtr_srs178.pdf

4 EL SECTOR FORESTAL DE MÉXICO HASTA EL AÑO 2100: PROYECCIONES Y ELEMENTOS PARA SU SEGUIMIENTO Y TOMA DE DECISIONES

THE FORESTRY SECTOR IN MEXICO UNTIL THE YEAR 2100: PROJECTIONS AND ELEMENTS FOR YOUR FOLLOW UP AND DECISION- MAKING

Javier Medina-Hernández⁴, Francisco José Zamudio-Sánchez¹, Alejandro Ismael Monterroso-Rivas², Gabriel Arcángel Rodríguez-Yam¹, Adriana Ávalos-Vargas¹

HIGHLIGHTS

- Aplicación de redes neuronales recurrentes LSTM de aprendizaje profundo en las proyecciones del sector forestal de México.
- Se estima al 2100 que, la superficie forestal arbolada disminuirá en 69 mil ha/año y la producción forestal maderable estará en un rango de 36 a 52 millones de m³.
- La importación y exportación presentan altibajos muy marcados.
- Se necesita instrumentar políticas públicas que mitiguen los efectos estimados del crecimiento en la demanda de una población en aumento.
- Se requiere desarrollar los sistemas de manejo forestal sostenibles en cada región de México, para reducir el deterioro de los recursos forestales.

4.1 Resumen

Introducción: Las actividades antropogénicas son la causa principal de la degradación de los bosques de México y del mundo. Se estima que el problema continuará aumentando por el crecimiento demográfico, las especies no nativas

Universidad Autónoma Chapingo, ¹División de Ciencias Forestales, ²Departamento de Suelos. Km 38.5 Carretera México-Texcoco. C. P. 56230. Chapingo, Texcoco, Estado de México. México.

y el cambio climático. Estos temas han adquirido mayor relevancia para la comunidad internacional debido a los eventos climáticos extremos y a la pérdida de recursos naturales.

Objetivos: Proyectar las tendencias de las variables clave del sector forestal de México hasta el año 2100, con bases de datos e inteligencia artificial, para orientar la toma de decisiones.

Materiales y métodos: Se proyectó la producción, importación y exportación forestal maderable y la superficie arbolada del país, a partir de series de tiempo (ST) anuales de 57, 57, 43 y 25 años respectivamente. Las proyecciones fueron realizadas a partir de redes neuronales recurrentes del tipo “Long Short-Term Memory” (LSTM) de múltiples capas ocultas y con la técnica propuesta en el presente de entrenamiento-proyección para proyectar cada año hasta el horizonte 2100. Se analizó el sector forestal a nivel nacional e internacional, para entender la situación actual de dicho sector.

Resultados y discusión: De seguir las tendencias observadas en los datos históricos, se prevé que al año 2100 disminuya la superficie forestal arbolada en 6 millones de hectáreas (mha) y que la producción forestal maderable se mantenga en un promedio de 44 millones de m³ (mm³) y se exporte e importe entre 40-50 y 25-50 mil m³, respectivamente. Se estima que, el crecimiento y necesidades de la población seguirán modificando los 138 mha forestales de México, esta superficie representa el 71 % del territorio nacional. El 48 % del área forestal es arbolada, la cual presenta vegetación modificada o alterada en poco más de la mitad de las mha (51 %).

Conclusión: Es posible proyectar ST a escala nacional de la actividad forestal de México hasta el año 2100, con el uso de inteligencia artificial y la técnica propuesta: ciclos entrenamiento-proyección. De persistir la degradación forestal de México y para satisfacer las necesidades presentes y futuras de la sociedad, se requerirá evaluar, crear e instrumentar políticas públicas y planes de manejo sostenibles enfocados a cada región.

Palabras clave: producción, importación y exportación forestal maderable; superficie forestal arbolada; series de tiempo; redes neuronales recurrentes LSTM; Deep Learning.

4.2 Introducción

En los avances de la Evaluación de los Recursos Forestales Mundiales 2020 (Global Forest Resources Assessments-FRA 2020), se estimó el área forestal global en 4 060 mha, cifra que equivale al 31 % del total de superficie de tierra en el mundo. La zona tropical, boreal, templada y subtropical corresponden 45, 27, 16 y 11 % de dicha superficie, respectivamente. Así mismo, Rusia, Brasil, Canadá, Estados Unidos de América y China, cuentan con el 54 % de esta superficie, con: 815, 497, 347, 310 y 220 mha respectivamente. La superficie mundial dedicada a la conservación de la biodiversidad se midió en 424 mha y para la protección del suelo y el agua se registraron 399 mha; sin embargo, del 2015 al 2020 se observó una disminución de 100 mha destinadas a la conservación (Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO], 2020).

Además, se calculó un aumento de 61 mha de la superficie forestal mundial, con respecto a lo que se registró en el FRA-2015 (FAO, 2016) y el FRA-2020. Lo que indica una disminución en la pérdida neta anual, la cual pasó de 7.8 mha, en el decenio de 1990-2000, a 5.2 y 4.7 mha en los períodos 2000-2010 y 2010-2020 respectivamente. Dicho evento se debió, en gran medida, al aumento de la superficie forestal en Asia, Oceanía y Europa. También, se calculó una expansión forestal total de 240 mha de 1990 a 2020, de los cuales solo el 7 % (290 mha) de los bosques son plantados y el resto se ha regenerado de manera natural (FAO, 2020).

En México, el Inventario Nacional Forestal y de Suelos 2009-2014 (INFyS), reportó una superficie forestal nacional cercana a los 138 millones de hectáreas, equivalente al 71 % del territorio nacional. Cabe señalar que esta superficie forestal incluye ecosistemas y 11 formaciones forestales (54 tipos de vegetación)

de la siguiente forma: matorral xerófilo (zonas áridas: 26.1 % y semiáridas: 14.7 %), bosques (coníferas y latifoliadas: 9.4 %, latifoliadas: 8.2 %, coníferas: 5.9 % y bosque mesófilo de montaña: 1.3 %), selvas (selvas bajas: 11.9 % y selvas altas y medianas: 9.8 %), otras áreas forestales no arboladas (11.5 %), manglares (0.7 %) y otras asociaciones arboladas (0.4 %) (Comisión Nacional Forestal [CONAFOR], 2018).

En cuanto al manejo forestal, se consideran como zonas arboladas a los siguientes ecosistemas: bosques, selvas, manglares y otras asociaciones; en conjunto esta categoría suma cerca de 66 mha, el equivalente al 48 % de la superficie forestal nacional, y son importantes para el ámbito forestal porque ahí se encuentra gran parte de los recursos forestales maderables. Mientras tanto, las zonas no arboladas, representadas por el matorral xerófilo y otras áreas forestales, ocupan más de la mitad de la superficie forestal, con poco más de 72 mha (CONAFOR, 2018).

La producción forestal maderable (PFM) de México se estimó en 47 mm³ para el 2018 (FAO, 2019a). Se incluye a los siguientes productos maderables de todas las especies forestales (coníferas y no coníferas): combustible de madera; trozas de aserrío y trozas para chapas; madera para pulpa, en rollo y partida; otra madera en rollo industrial. Los estados que presentaron la mayor producción de madera en rollo (r) industrial son: Durango, Chihuahua, Oaxaca, Tabasco y Michoacán, con el 28, 19, 8, 7 y 5 % del total nacional, respectivamente, el cual fue de 9 mm³r para el 2017; por lo tanto, se obtuvo un incremento de 2.3 mm³r, con respecto a los 6.7 mm³r medidos en el 2016 (Secretaría del Medio Ambiente y de los Recursos Naturales [SEMARNAT], 2020).

Dicha PFM se utiliza, en parte, para las exportaciones forestales maderables (EFM), estimadas en más de 58 mil m³ para el año 2018. En el mismo año, las importaciones forestales maderables (IFM) se calcularon en más de 5 mil m³. Dentro de las EFM y las IFM se agrupan los siguientes productos forestales: combustible de madera (no coníferas) y madera en rollo industrial de coníferas, tropicales y otras (FAO, 2019a).

Para observar las posibles consecuencias de la problemática del sector forestal de México, don de ayuda proyecciones de largo plazo, más allá de los altibajos del corto plazo que son propios del ciclo económico y político (PwC UK, 2017). Las proyecciones aportan información necesaria para orientar a los tomadores de decisiones involucrados con el sector forestal, con el fin de generar los mayores beneficios económicos y/o sociales (Aguirre-Calderón, 2015; Wear & Greis, 2013).

Lo anterior es posible realizarlo utilizando series de tiempo (ST). En general, el comportamiento y las observaciones no son independientes, sino que se correlacionan con las anteriores, incluso se desarrollan lentamente con el tiempo (Levendis, 2018). En este sentido, las redes neuronales recurrentes (recurrent neural network-RNN) han sido utilizadas como herramienta para la obtención de proyecciones, ya que se ha demostrado su eficiencia en la predicción de variables que dependen del tiempo. Producen los errores más bajos en comparación con otros tipos de redes neuronales artificiales (artificial neural network-ANN) y métodos convencionales, como: perceptrón multicapa, promedio móvil, modelos de regresión automática, ARIMA, Holts Winter y otros (Adam, Smagulova & James, 2018; Kurumatani, 2018; Samarawickrama & Fernando 2017).

Actualmente, las RNN y su variante específica conocida como redes recurrentes profundas LSTM o “Deep LSTM” (DLSTM) son utilizadas por el rendimiento superior que se obtiene en el modelado de dependencias de datos secuenciales a corto y largo plazo, porque resuelven el problema de gradiente de fuga, mantiene un error constante que transcurre en el tiempo y se diferencian de las RNN simples (SRNN) por instrumentar una unidad de procesamiento interna más elaborada, conocida como “celda” (Bianchi, Maiorino, Kampffmeyer, Rizzi, & Jenssen, 2017; Hochreiter & Schmidhuber 1997).

Se han aplicado las RNN-LSTM en numerosas áreas que requieren de reconocimiento de patrones y aprendizaje automático (Schmidhuber, 2015), además, son muy populares en la proyección de ST del mercado financiero (Fischer & Krauss, 2018), pero para el sector forestal mundial solo se encontró

un trabajo que utilizó este tipo de red neuronal para la predicción de la escala de incendios forestales en Alberta, Canadá (Liang, Zhang, & Wang, 2019) y, en el caso de México, no se tiene investigación publicada que proyecten variables del sector forestal mexicano con el uso de inteligencia artificial.

Desde este enfoque, el objetivo del presente es proyectar hasta el año 2100 variables clave en el sector forestal de México: producción, importación y exportación forestal maderable y superficie forestal arbolada, a partir de bases de datos históricas a escala nacional y redes neuronales de aprendizaje profundo, para mostrar el posible futuro de continuar con las tendencias actuales en el sector forestal y que sirva como base para describir las probables consecuencias de las actividades antropogénicas y toma de decisiones.

4.3 Materiales y métodos

4.3.1 Datos

Se seleccionaron cuatro variables que ejemplifican, de forma general, la tendencia del sector forestal en México: PFM, IFM, EFM y SFA. Los datos históricos anuales se descargaron de la Base de Datos Estadísticos Corporativos de la FAO (2019a) y se obtuvieron los siguientes períodos para cada una de las ST: PFM: 1961-2018; SFA: 1990-2015; IFM: 1961-2018 y EFM: 1975-2018.

Las series de tiempo se trabajaron aisladamente cada una a partir del siguiente procedimiento: se diseñó la red, se realizó el entrenamiento y se estimó la proyección del año inmediato, los cuales se describen a continuación. La técnica de ciclos entrenamiento-proyección se realizó año por año hasta el horizonte 2100, en cada una de las ST.

4.3.2 Software y hardware

Para habilitar el modelo y arquitectura de ANN se requirió de bibliotecas de software (Tensorflow-gpu, Keras y Sklearn), controladores para usar la interfaz de programación CUDA, Python 3.8.2 a través de Anaconda Navigator (para

mayor información de los requisitos e instalaciones revisar: Chollet, 2018 o Gulli & Pal, 2017) y un ordenador portátil con procesador Intel i7 de octava generación, 2.21 GHz de velocidad base, 16 GB de memoria RAM, tarjeta NVIDIA® GeForce® GTX 1050 Ti, 12 GB de memoria de la unidad de procesamiento gráfico (GPU) y sistema operativo Windows® 10 de 64 bits. Se utilizó la librería de red neuronal profunda, o NVIDIA CUDA® Deep Neural Network (cuDNN), porque permite una mayor velocidad en el procesamiento de los datos, vía GPU (Figura 36), en comparación con la que se obtiene en una unidad central de proceso o CPU (Appleyard, Kocisky, & Blunsom, 2016; NVIDIA, 2020).



Figura 36. Los dos hardware y software básicos para aprendizaje profundo. Fuente: Adaptado de Chollet, 2018.

4.3.3 RNN-LSTM: diseño y funcionamiento

Las SRNN son máquinas de aprendizaje que calculan recursivamente nuevos estados o datos de entrada (x_t), mediante la aplicación de la función no lineal que, en general, es la tangente hiperbólica (g_1), a estados de entradas anteriores (h_{t-1}) (Figura 2). La función no lineal y la arquitectura de las RNN que se eligen dependen de la naturaleza del problema, además, determinan cómo fluye la información. De ahí que, éstas sean esenciales para realizar un sistema de aprendizaje robusto (Bianchi et al., 2017; Greff, Srivastava, Koutník, Steunebrink, & Schmidhuber, 2017).

Además, en las RNN se usa una sola capa de red neuronal con la función de aprendizaje recurrente; mientras que en LSTM se usan las celdas en los bloques recursivos y constan de funciones principales o puertas: entrada, salida y olvido (Figura 37). Las celdas LSTM ayudan a entrenar el modelo de manera más efectiva cuando se pasan secuencias largas, aprendiendo selectivamente o

borrando información (Fandango, 2018), ya que las puertas multiplicativas permiten que las celdas de memoria LSTM almacenen y accedan a la información durante largos períodos, mitigando así el problema gradual de desaparición (Graves, 2012; Graves & Schmidhuber, 2005).

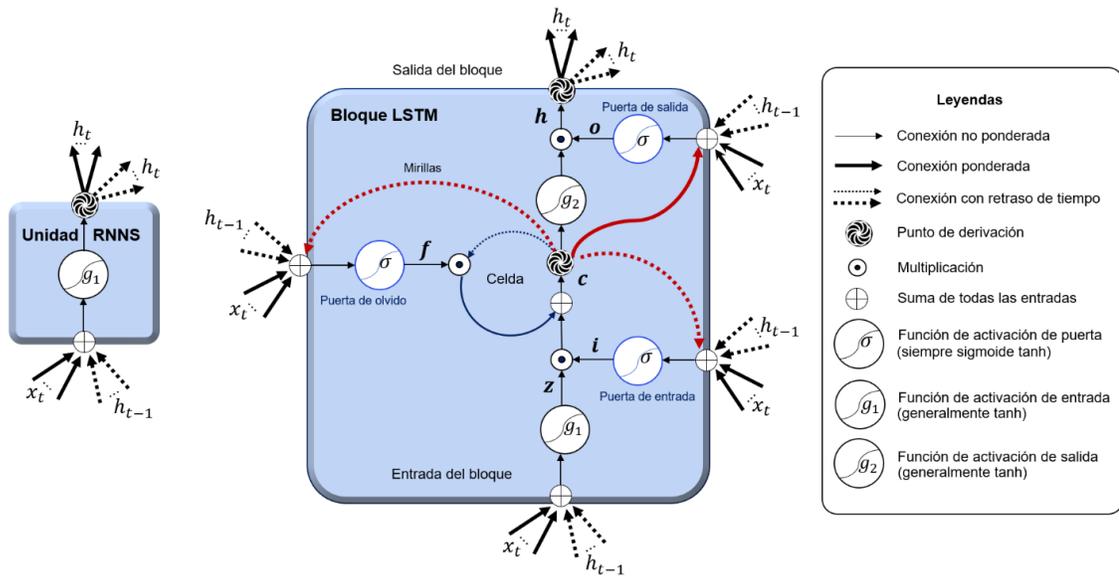


Figura 37. Esquema detallado del funcionamiento de una unidad de SRNN y un bloque de RNN-LSTM. La unidad SRNN solo cuenta con una función de activación de entrada y un punto de derivación. Por su parte el bloque LSTM presenta funciones más complejas en la entrada, salida y las tres puertas del bloque: entrada, olvido y salida. Además, se caracteriza por la celda (el Carrusel de error constante), una función de salida y conexiones de mirilla. Las salidas del bloque se conectan de forma recurrente a las entradas y puertas del bloque y de otros bloques de las capas profundas de la red. Fuente: Adaptado de Greff et al., 2017.

En las siguientes líneas se describen las ecuaciones que muestran el cálculo de la entrada y salida del bloque y las puertas de la celda LSTM. La salida del bloque se conecta de forma recurrente a la entrada del bloque, las puertas de este bloque y a otros bloques de la red DLSTM (para observar las conexiones ver Figura 3) (Bianchi et al., 2017; Greff et al., 2017; Fandango, 2018; Graves, 2012; Gulli & Pal, 2017).

Puerta de olvido: Las conexiones recurrentes de las celdas en el paso del tiempo anterior (h_{t-1}) y los x_t fluyen a la capa de red neuronal de la puerta de

olvido (f^t) para producir los datos de salida (h_t), en el tiempo (t), de acuerdo con la siguiente ecuación:

$$f^t = \sigma(\omega^{(fx)} \cdot x_t + \omega^{(fh)} \cdot h_{t-1} + p^{(f)} \odot c_{t-1} + b^{(f)}), \quad (1)$$

donde: $\omega^{(fx)}$ es la matriz de los pesos para la entrada x_t , $\omega^{(fh)}$ es la matriz de peso de las conexiones recurrentes, $p^{(f)}$ es el vector de pesos de las mirillas, c_{t-1} es el estado de la celda en el tiempo ($t - 1$) y $b^{(f)}$ es el vector de sesgos. Las mirillas son las únicas conexiones ponderadas desde la celda a las puertas, todas las demás conexiones dentro del bloque no están ponderadas (o, de manera equivalente, tienen un peso fijo de 1.0). El producto punto de dos vectores se representa con \odot .

En f^t se decide qué información debe descartarse del estado de la celda anterior (h_{t-1}). Aquí se usa la función de activación no lineal sigmoide logístico ($\sigma(x) = \frac{1}{1+e^{-x}}$), de modo que una salida de 1 (puerta abierta) representa que la información se transfiere al siguiente paso dentro de la celda y una salida de 0 (puerta cerrada) consiste en descartar la información selectivamente.

Entrada de bloque: Se calcula a partir de h_{t-1} y x_t con la función no lineal de activación de entrada de bloque que, generalmente, es la tangente hiperbólica ($g_1(x) = g_2(x) = \tanh(x)$), según la siguiente ecuación:

$$z^t = g_1(\omega^{(zx)} \cdot x_t + \omega^{(zh)} \cdot h_{t-1} + b^{(z)}), \quad (2)$$

donde: $\omega^{(zx)}$, $\omega^{(zh)}$ y $b^{(z)}$ son las matrices de los pesos de x_t , h_{t-1} y el vector de sesgos para z , respectivamente.

Puerta de entrada: La función de la puerta de entrada (i^t) opera, con las capas de redes neuronales, en h_{t-1} después de haber sido modificada por f^t y en ella se decide cuánto debe ser actualizado el nuevo estado c_t con un nuevo candidato z^t . La ecuación es la siguiente:

$$i^t = \sigma(\omega^{(ix)} \cdot x_t + \omega^{(ih)} \cdot h_{t-1} + p^{(i)} \odot c_{t-1} + b^{(i)}), \quad (3)$$

donde: $\omega^{(ix)}$, $\omega^{(ih)}$, $p^{(i)}$ $b^{(i)}$ son las matrices de los pesos de x_t , h_{t-1} , mirillas y el vector de sesgos para i , respectivamente.

Después, los cálculos de las Ecuaciones (1), (2) y (3) se combinan para obtener la actualización de la memoria a largo plazo (c_t), denotada en la siguiente ecuación:

$$c_t = c_{t-1} \odot f^t + z^t \odot i^t, \quad (4)$$

Puerta de salida: Esta puerta selecciona cuánta información se puede usar para actualizar la memoria de trabajo y la parte del estado que se devolverá como salida, para ello se utiliza la función σ , según la siguiente ecuación:

$$o^t = \sigma(\omega^{(ox)} \cdot x_t + \omega^{(oh)} \cdot h_{t-1} + p^{(o)} \odot c_{t-1} + b^{(o)}), \quad (5)$$

Donde: $\omega^{(ox)}$, $\omega^{(oh)}$, $p^{(o)}$ $b^{(o)}$ son las matrices de los pesos de x_t , h_{t-1} , mirillas y el vector de sesgos para o , respectivamente.

Finalmente, en la **salida del bloque** (h_t) la memoria de trabajo se actualiza al filtrar la Ecuación (4) con la función de activación de salida de bloque, que usualmente es g_2 (en algunos casos g_2 es la función identidad) y multiplicar el resultado con el vector de la Ecuación (5), de la siguiente forma:

$$h_t = g_2(c_t) \odot o^t, \quad (6)$$

Cada puerta depende de la entrada externa actual (x_t), del número de entradas (M), de las celdas anteriores de salida (h_{t-1}), del número de bloques LSTM (n) y del número de salidas N (Greff et al., 2017). En la práctica la actualización y las puertas de olvido nunca están completamente abiertas o cerradas debido a la forma funcional del sigmoide, que se satura sólo para valores infinitamente grandes (Bianchi et al., 2017).

Para la creación de una red DLSTM se requiere de una arquitectura de múltiples capas ocultas que constan de un conjunto de bloques de memoria conectados de forma recurrente (Figura 38). La red interactúa solo con las células a través de las puertas (Graves, 2012; Graves & Schmidhuber, 2005). Las DLSTM pueden manejarse con parámetros diferentes para cada capa apilada (Fandango, 2018), lo que permitió una mayor posibilidad de resolver este problema univariante en específico con la arquitectura descrita a continuación.

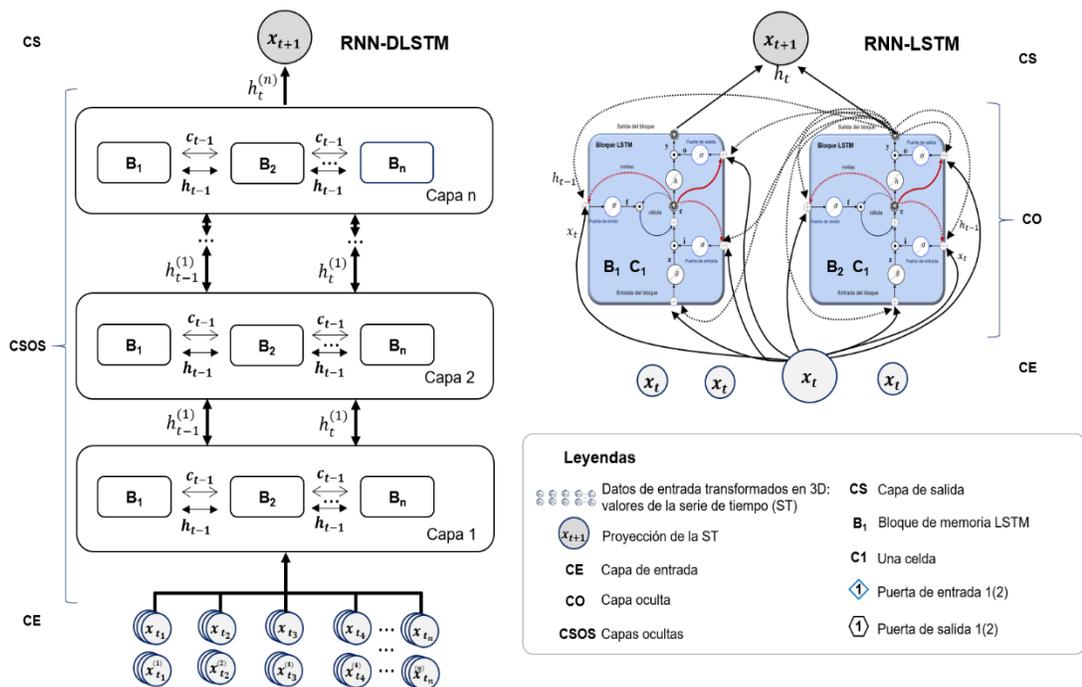


Figura 38. Diagrama de la arquitectura de una red neuronal recurrente profunda (RNN-DLSTM) que se caracteriza por presentar varios bloques de una celda cada uno, que a la vez se encuentran unidos en varias capas ocultas; además, se presentan cinco unidades de entrada y una unidad de salida. En comparación con una red neuronal recurrente (RNN-LSTM) de una sola capa oculta, en la cual se muestran a detalle las conexiones de los datos de entrada (x_t) y las conexiones recurrentes (x_{t-1}), en este caso se tienen cuatro unidades de entrada y una unidad de salida. Cada bloque de la RNN-LSTM presenta cuatro entradas: entrada a bloque y las tres puertas (entrada, olvido y salida). No se presentan todas las conexiones. Fuente: Elaboración propia con información de Greff et al., (2017); Sagheer y Kotb (2019); Graves (2012); Hochreiter y Schmidhuber (1997); y Adam et al. (2018).

4.3.4 RNN-DLSTM: Arquitectura y parámetros generales utilizados

Para la ST de la PFM se utilizaron tres capas ocultas con 400, 200 y 200 neuronas cada una en un entrenamiento de 200 épocas (una época representa el ajuste de los pesos para todos los pares de entrenamientos, por lo que se requiere de un número significativo de épocas para un entrenamiento). Las ST de la EFM e IFM se trabajaron con tres capas con 200, 100 y 100 neuronas cada una y un entrenamiento de 200 épocas. Finalmente, la ST de la SFA requirió de 140 neuronas en cada una de las tres capas y un número de 660 épocas.

4.3.5 Ciclos de entrenamiento-proyección

Para atender el objetivo de obtener las proyecciones (θ) a largo plazo de las ST, utilizando los x_t para cada dato anual posterior, se consideró predecir un año a la vez y tomarlo en el entrenamiento (δ) posterior. Es decir, se entrenó (δ_1) la red DLSTM para realizar la θ_1 que aporte el dato anual posterior de la ST (x_{t+1}). El dato nuevo se consideró como “dato real” (\hat{x}_t) para obtener la θ_2 con el δ_2 y, a la vez, obtener el nuevo valor anual x_{t+2} . Se volvió a utilizar x_{t+n} como dato real de la ST para obtener la θ_n con el δ_n y, estimar finalmente el valor anual x_{t+n} (Figura 39). En donde n es el último valor de la proyección correspondiente al año 2100. Se propuso esta metodología para evitar que se sobresaturara la DLSTM con proyecciones muy largas y de esta manera reducir el error blanco que crece al generar proyecciones a largo plazo.

El entrenamiento de las RNN DLSTM se basa en los x_t de la ST que se producen en una salida temporal deseada (\hat{h}_t). De esta manera, la función de pérdida es el objetivo por minimizar, ya que depende del error entre la salida estimada (\hat{h}_t) y la salida real de la red (h_t) (Fandango, 2018). Por lo que, para medir la precisión de la proyección y la evaluación del rendimiento o desempeño se utiliza, habitualmente, el error cuadrático medio $MSE = \frac{1}{n} \sum_{i=1}^n (h_t - \hat{h}_t)^2$, la raíz cuadrada del error cuadrático medio $RMSE = \sqrt{MSE}$ y el porcentaje del error con respecto a los datos reales $PDE = \frac{x_t}{RMSE} * 100$ (Klabi, 2014, Regal et al., 2019).

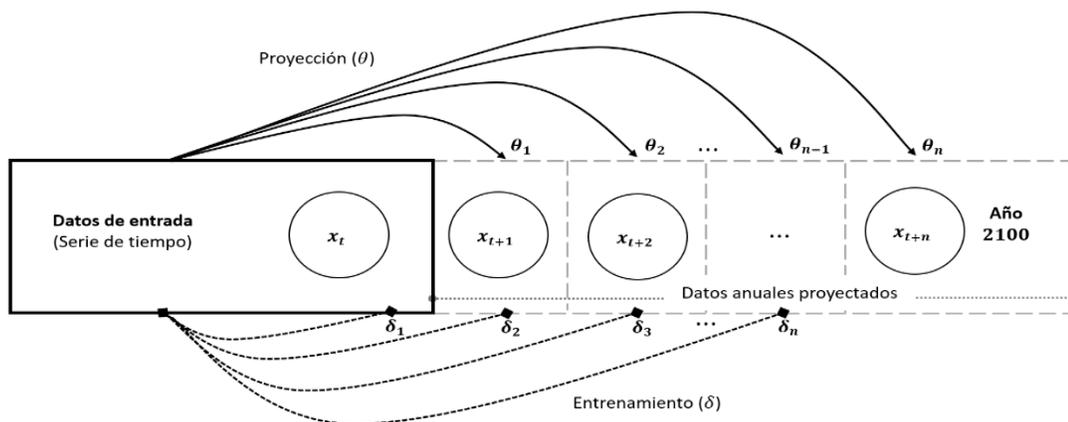


Figura 39. Esquema de la técnica entrenamiento-proyección utilizada para obtener cada uno de los datos anuales proyectados. En cada uno de los datos anuales obtenidos se realizó un nuevo entrenamiento (θ) previo a la realización de su respectiva proyección (δ) para obtener el dato posterior. Fuente: Elaboración propia.

4.3.6 Descripción de las proyecciones

Por último, se realizó una revisión de literatura relacionada con la situación pasada, presente y futura del sector forestal de México, para describir y realizar un análisis general del panorama que presentan las proyecciones obtenidas.

4.4 Resultados

4.4.1 Desempeño de las proyecciones

Las proyecciones obtenidas con las RNN-DLSTM y los ciclos de entrenamiento-proyección presentaron, en general, medidas de desempeño bajas, con un RMSE de poco más de 200 ha, al comparar el dato observado con la proyección obtenida de la SFA de México (Figura 40). Para la PFM, IFM y EFM se calculó un PDE de 1, 18 y 25 %. Los datos atípicos en las ST de la IFM y EFM afectaron las proyecciones.

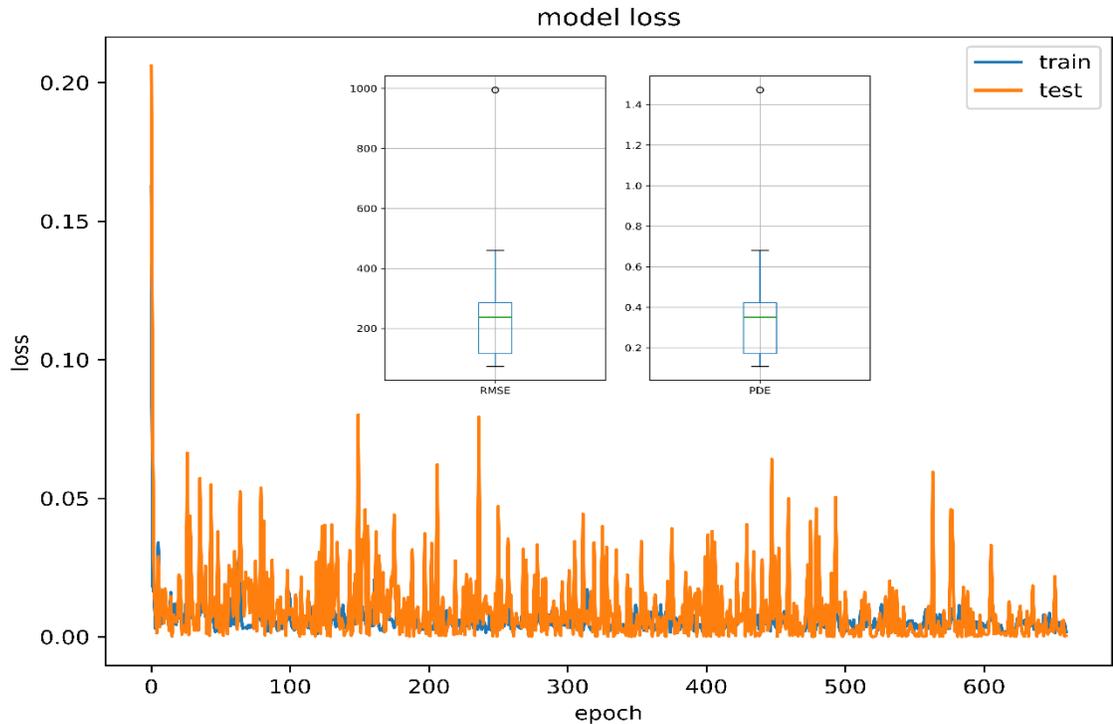


Figura 40. Medidas de evaluación del desempeño de la proyección de la SFA de México. Se observa que el error (loss) disminuye conforme pasan las épocas en el entrenamiento y se obtuvieron valores bajos en RMSE y PDE. Fuente: Elaboración propia.

4.4.2 Proyecciones de las variables al 2100

En cada una de las cuatro ST, se presentan los intervalos de confianza (IC) al 80 y 99 %, los cuales, permiten describir los posibles futuros o escenarios que se pueden obtener como resultado hasta el año 2100. Esta información adicional a las proyecciones aporta un rango en el cual los datos futuros pueden presentarse. Se obtuvieron los siguientes resultados clave que describen un posible futuro del sector forestal de México hasta el año 2100:

Se calcularon cerca de 3.8 mha de **SFA**, pérdida durante el periodo: 1990-2015. De continuar con la tendencia observada en los datos históricos se prevé que disminuya la SFA en cerca de 6 mha al año 2100, con una tasa de pérdida anual aproximada de 71 mil ha. La proyección tendencial descrita, es el escenario general, que puede variar en otros dos futuros estimados: el primero es el escenario “negativo” en el que se reduce considerablemente la SFA hasta

presentar, en el año 2100, una pérdida de más de 16 mha y el segundo escenario de esta proyección es, el “favorable”, que registrará un aumento de 2 mha para el 2100 (Figura 41).

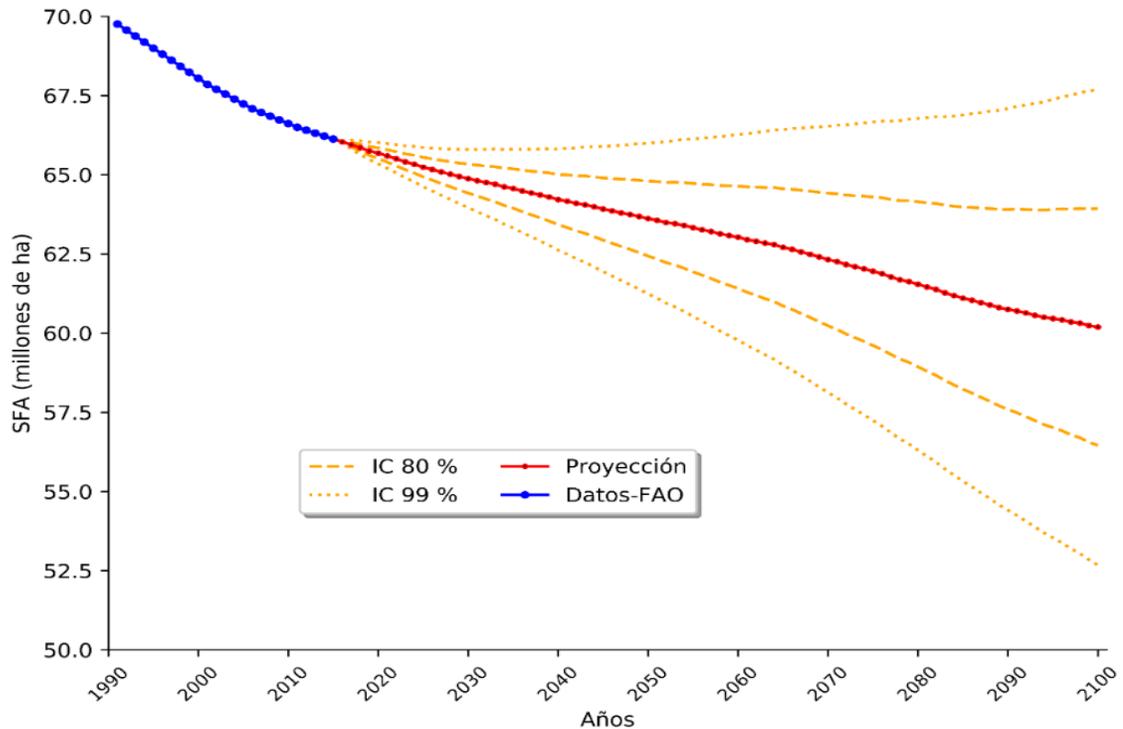


Figura 41. Superficie forestal arbolada (SFA) de México con su proyección hasta el año 2100 e intervalos de confianza (IC). Se observa una evidente tasa constante de pérdida de la SFA, consecuencia de las actividades antropogénicas y la falta de políticas públicas enfocadas en promover la actualización e instrumentación de planes de manejo sostenibles y eficientes, adaptados a cada región del país. Fuente: Elaboración propia con datos de la FAO (2019) para el período: 1990-2015.

La **PFM** presentó los siguientes tres períodos de crecimiento, marcados por una tendencia positiva y una contracción en la producción: 1961-1977, 1978-1989 y 1990-2000. Posterior al año 2001 y hasta el último dato registrado (2018), se observó que el crecimiento de la PFM se detuvo, en comparación con los períodos anteriores. Por lo cual, para el 2100, se calculó un promedio de la PFM de 45 mm³ y un intervalo (80 % de confianza) de 36 a 52 mm³ (Figura 42).

En el caso de la ST de la **IFM**, se encontró que se caracteriza por no presentar tendencia, estacionalidad o ciclos. Además, se observan datos atípicos en cuatro

años (2004-2008) de la ST, los cuales superan en casi 31 mil m³ a la media de las importaciones del período anterior a esta alza (1961-2003). A largo plazo, se proyecta un futuro con altibajos, con una cantidad promedio estimada de 38 mil m³, que se encuentra entre un intervalo máximo (80 % de confianza) cercano a los 100 mil m³ y un intervalo mínimo que supera los 0 m³ de productos forestales importados (Figura 43).

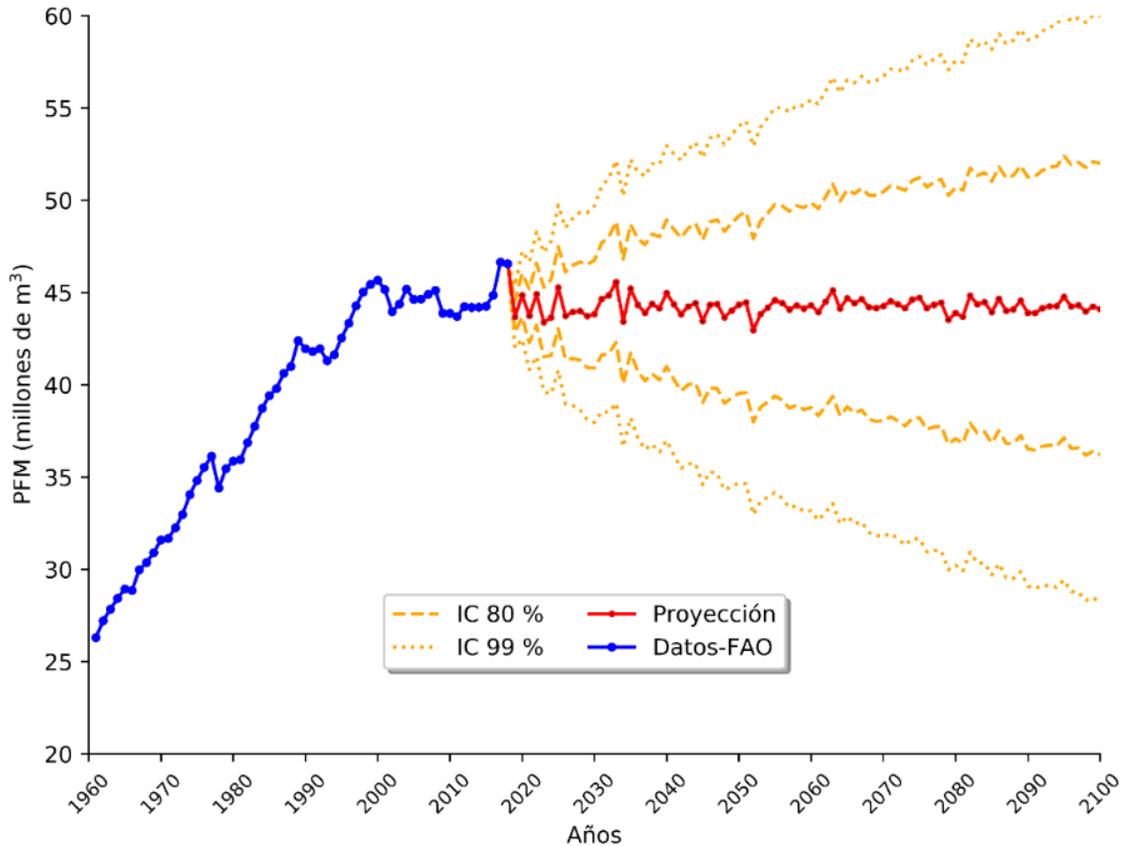


Figura 42. Producción forestal maderable (PFM) de México con su proyección hasta el año 2100. En la suma anual reportada se consideran el combustible de madera, trozas de aserrío y chapas, madera en pulpa, rollo y partida, además de otra madera en rollo industrial. Se estima que, hasta el año 2100, la producción sea constante, como primer escenario, aunque es posible que se vea merma por la sobreexplotación, la pérdida del área forestal, el crimen organizado, la demanda de una población en crecimiento, etcétera. Los avances tecnológicos, los planes de manejo sostenible y el manejo forestal comunitario podrían generar un aumento en la productividad del territorio nacional que actualmente se encuentra en producción. Fuente: Elaboración propia con datos de la FAO (2019) para el período: 1961-2018.

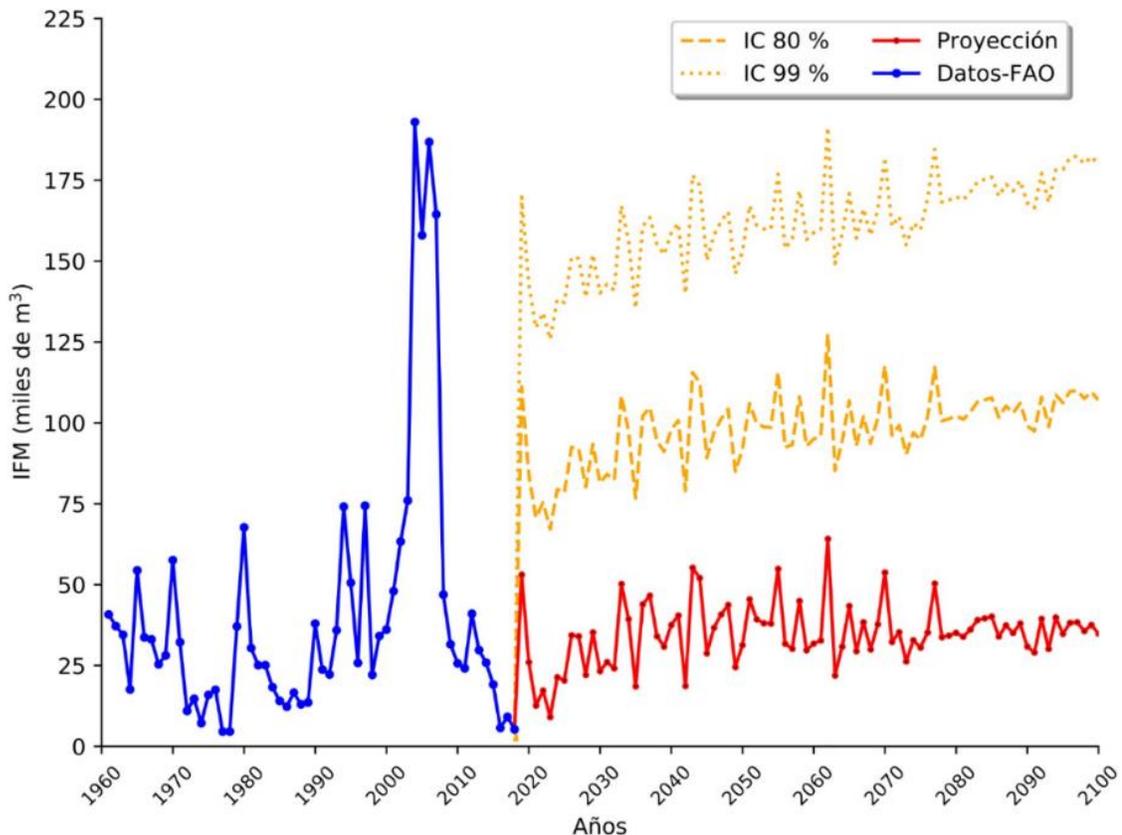


Figura 43. Proyección de la importación forestal maderable (IFM) de México. Las importaciones y los productos forestales provenientes del contrabando son los que cubren una demanda cada vez mayor, que supera en más de tres veces la producción autorizada o legal (Chapela & Merino, 2019). De persistir con esta situación, es probable que las IFM aumenten durante el periodo 2018-2100. Fuente: Elaboración propia con datos de la FAO (2019) para el período: 1961-2018.

Por otro lado, se midieron cerca de 10 mil m³/año de 1961 a 2011 de **EFM** en México. Posterior a estas fechas, se presentó un aumento de más de seis veces el valor promedio descrito, comparado con la media de las exportaciones durante el periodo 2012-2018. La variación se presentó por los valores atípicos que van de los 28 a 135 mil m³. Por lo tanto, esta ST presentó un crecimiento positivo con altibajos marcados, lo que dará como resultado un crecimiento similar, hasta llegado el año 2100 y en promedio se espera que se exporten 45 mil m³, con valores anuales que variarán entre los 10 y 120 mil m³ en el año 2100, al considerar el IC al 99 % (Figura 44).

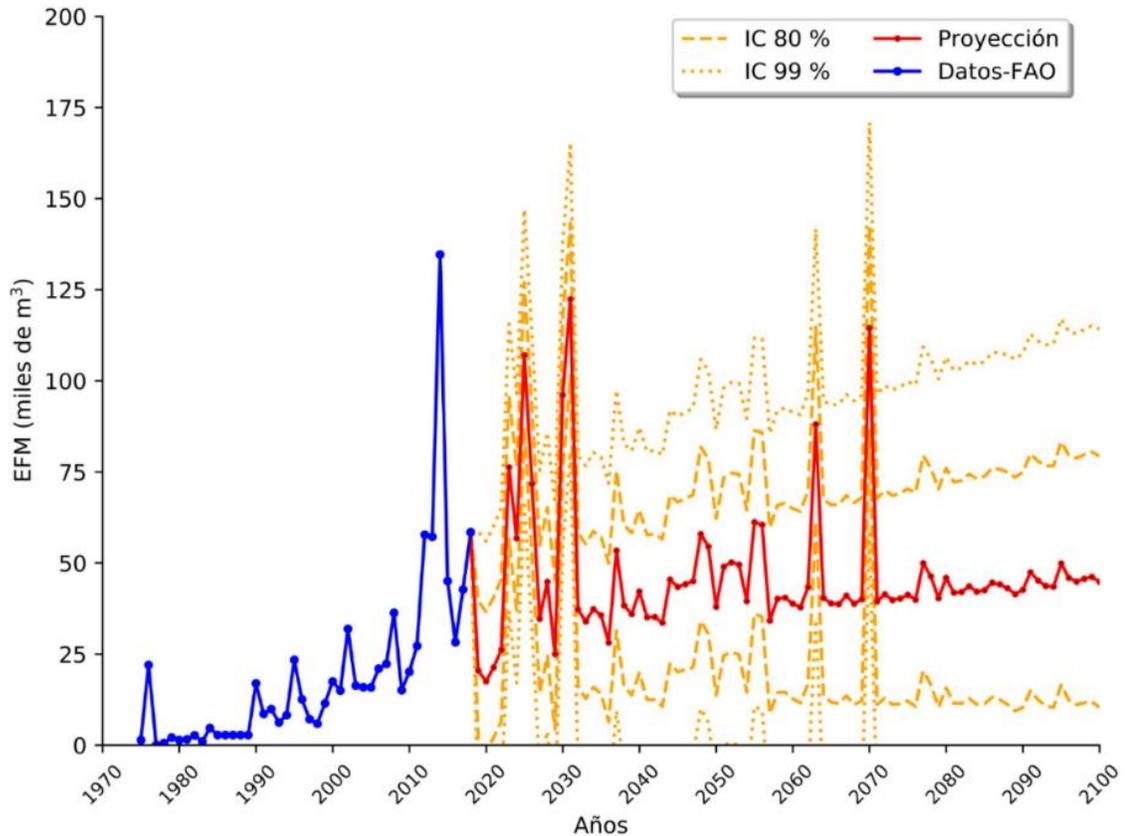


Figura 44. Exportación forestal maderable (EFM) de México y su proyección hasta el año 2100. Con los datos del pasado, se evidencia que México no es un país con un índice alto de exportaciones, debido, en gran medida, a la pérdida de competitividad que existe con relación al comercio internacional. A pesar de ello, en los últimos años se ha visto un alza importante que supero en más de seis veces a la media de las décadas anteriores, por lo que es muy posible que se siga registrando aumentos importantes en esta actividad. Los factores que desarrollarán las EFM son: la eficiencia en la producción, productividad y comercialización. Fuente: Elaboración propia con datos de la FAO (2019) para el período: 1975-2018.

4.5 Discusión

Los resultados indican que es factible utilizar las RNN-DLSTM para proyectar ST, ya que exhibieron una precisión alta, lo que las hace una técnica de vanguardia para el aprendizaje secuencial y la proyección de variables en el sector forestal de México. Las RNN-DLSTM también demostraron ser adecuadas para este dominio en la investigación de Liang et al., (2019) y Fischer y Krauss (2018).

Por otro lado, si persisten las tendencias y condiciones que se muestran en la ST de la SFA de México se estaría perdiendo, para el año 2100, la superficie forestal equivalente al área de tierra que ocupa el estado de Michoacán de Ocampo (60 mil km²). Esta tendencia se ha observado a nivel mundial, en las últimas tres décadas, debido a que se ha perdido una superficie forestal mundial mayor a 178 mha, valor semejante a la mitad del área forestal de Canadá. Esta situación se generó, principalmente, por la disminución del área forestal en las zonas subtropical y tropical, donde destaca América del Sur con un estimado de 129 mha y África con más de 106 mha, consecuencia de una disminución anual de 4.3 y 3.5 mha respectivamente. De igual manera, en el mismo periodo, se registró una pérdida de 420 mha de bosque en todo el mundo, por causa de la deforestación de más de 13 mha/año; sin embargo, se calculó una disminución progresiva de dicha tasa, por lo que, se obtuvo una pérdida anual de 10 mha en el último quinquenio (FAO, 2020).

Las actividades antropogénicas (cambio de uso de suelo, deforestación, sobre explotación de los recursos naturales, entre otros), los factores bióticos (plagas y enfermedades) y abióticos (incendios y vientos) han sido y, con verosimilitud, serán las causas principales de la modificación, alteración o pérdida de cerca de un tercio de la SFA de México, la cual se caracterizan por presentar vegetación secundaria. El resto de la SFA presenta vegetación primaria (69 %), vegetación que no presenta indicios de perturbación. Además, se calcula que cerca de 34 y 10 mha de zonas arboladas y no arboladas presentan vegetación secundaria, principalmente en los siguientes tipos de formaciones forestales: selvas altas y medianas, selvas bajas, bosque mesófilo, bosque de latifoliadas, bosque de coníferas y latifoliadas y bosque de coníferas, debido a que solo conservan el 24, 42, 46, 57, 63 y 64 % de la vegetación primaria, respectivamente (CONAFOR, 2018).

Este deterioro también se encuentra condicionado, a largo plazo, por otros factores interrelacionados, de los que destacan: el cambio de uso del suelo (Bonilla-Moheno & Aide, 2020), el calentamiento global (Menezes et al., 2019); el

cambio climático (Monterroso & Conde, 2015), los medios de vida rurales, la instrumentación de nuevas tecnologías (Lorenzen, Orozco-Ramírez, Ramírez-Santiago, & Garza, 2020), la deficiencia en el manejo forestal sostenible (MFS) (Sheppard et al., 2020; Trujillo-Miranda, Toledo-Aceves, López-Barrera, & Günter, 2020), los incendios forestales (Monjarás-Vega et al., 2020), la invasión de especies exóticas (causado por el crecimiento de la superficie de bosque plantado y de las plantaciones forestales; Bucharova & Krahulec, 2020; FAO, 2020), la falta de financiamiento, mercados favorables y la recopilación de datos (Siry, Cubbage, Potter, & McGinley, 2018).

Además, dichos factores limitan el desarrollo de este sector, máxime cuando existe una inadecuada instrumentación de las políticas públicas nacionales e internacionales (Santana et al., 2020), se sobreexplotan los recursos por efecto de la demanda de una población mundial en crecimiento (se estiman 705 mil personas/año en México del 2020 a 2060 y 39 millones de personas/año en el mundo del 2020 a 2100 y ; Organización de las Naciones Unidas [ONU], 2019) y continua el aumento en el número de personas en situación de inseguridad alimentaria a nivel nacional, regional y mundial (FAO, 2019b). Dicha problemática se agravará por la nueva recesión económica provocada por la pandemia del COVID-19 (Ali & Alharbi, 2020; Goodell, 2020; Huang et al., 2020), que generó un impacto social: a la fecha, ha causado la muerte de más de un tercio de millón de personas (Organización Mundial de la Salud [OMS], 2020) y, se estima que, el número de personas en situación de pobreza aumente; además de un impacto económico sin precedentes: se midió, en todos los sectores, una pérdida de más de 6 mil millones de dólares (Bloomberg Economics, 2020).

Aunque se espera que después del 2060 y hasta llegado el 2100 la población de México disminuya en -391 mil personas/año y que, a nivel mundial, el número de personas aumente en 80 años, similar a lo que aumentó en los últimos 40 (debido a que se calculó y estimó un aumento de 3,337 y 3,080 millones de personas en los periodos 1980-2020 y 2020-2100, respectivamente; ONU, 2019) no se puede considerar un futuro favorable, porque ya se generó una contaminación ambiental

(Alimba & Faggio, 2019; Harrison, 2014; Liu, Guo, & Xiao, 2019) y agotamiento de los recursos naturales sin precedentes (Foley, 2011; Lorenz et al., 2018; Meadows, Meadows, Randers, & Behrens III, 1972; Whitmee, 2015). Inclusive, se ha determinado a esta época geológica actual como Antropoceno, que se caracteriza por el momento en el que las actividades humanas comenzaron a modificar, sustancialmente y a nivel global, las condiciones biofísicas del planeta Tierra (Lorenz et al., 2018; Whitmee, 2015). Se han propuesto diferentes fechas para estimar el comienzo de esta época, pero la más aceptada es la de mediados del siglo XX (Steffen, Broadgate, Deutsch, Gaffney, & Ludwig, 2015).

De persistir los problemas descritos y el modelo de crecimiento económico mundial, con la inadecuada gestión de los recursos naturales y el consumismo insostenible, entonces es muy probable que en las próximas décadas se presente una reducción constante del desarrollo y bienestar humano (Organización para la Cooperación y el Desarrollo Económicos [OECD], 2012).

Por su parte, la PFM podría mantenerse constante o disminuir con el paso de las décadas. En el mundo, existe un problema similar, ya que se calculó un descenso de 19 y 37 mha en la superficie forestal destinada a la producción, entre los períodos 2010-2015 y 2015-2020 respectivamente (FAO, 2015). El valor que se calculó para el área de la producción maderable y no maderable fue de 1,150 mha, el equivalente a un tercio de todos los bosques del mundo (FAO, 2020). En los últimos años, la producción de madera en rollo industrial ha estado liderada por países de ingresos altos e ingresos medianos altos, con 1,014 y 291 mm³r/año respectivamente.

Situación que se verá marcada también en el crecimiento de las IFM y EFM de México. Se prevé que México continúe en la lista de los países de ingresos medianos-bajos y bajos que utilizan la extracción de madera básicamente como combustible, donde este grupo de países destinan 637 y 439 mm³r/año respectivamente. Además, es preciso considerar que India, EUA, Brasil, Rusia y Canadá son los países con mayores volúmenes de extracción de madera en rollo, con: 435, 324, 229, 197 y 150 mm³r, respectivamente (FAO, 2016).

Desde este enfoque, se requiere de actualizar y generar políticas públicas (Santana et al., 2020) que ayuden a minimizar el efecto a futuro que provocarán las actividades antropogénicas en el sector forestal de México, tales como: el cambio de uso de suelo para la ganadería, agricultura y zonas urbanas (Bonilla-Moheno & Aide, 2020; Creutzig, 2019); el manejo y aprovechamiento forestal (Fraser, 2019); los incendios forestales (Ferreira, 2020; Monjarás-Vega et al., 2020); y la generación de energía (Brinkmann, 2020). Si no se trabaja en las políticas públicas referidas y, además, se continúa con: el aumento de la PFM (como se observó de 1961 al 2000), la baja actividad en la IFM y la tendencia creciente de las EFM (con exportaciones de algunos períodos que sobrepasan la media anual), entonces se seguirán perdiendo progresivamente la biodiversidad, los sistemas biológicos únicos (Mondal, Saha, & Roy, 2019; Newbold et al., 2015), la captura de carbono (Sharma et al., 2020), la cantidad y calidad del agua (Brinkmann, 2020) y aumentarán los eventos climáticos extremos (Bush, 2020; Monterroso & Conde, 2015).

Situación que advierte a los investigadores, los tomadores de decisiones y la población en general sobre los efectos que trae el no seguir una gobernanza ambiental sostenible, con políticas públicas guiadas por los estudios que prevén las consecuencias de la acción del hombre en la naturaleza (Ali & Alharbi, 2020; Bloomberg Economics, 2020; Goodell, 2020; FAO, 2019b). Por lo que, la comunidad internacional ha tenido más interés en generar un nuevo enfoque, principalmente en temas relacionados con la protección de los bosques (Gryazkin, Bepalova, Samsonova, Belyaeva, & Belyaev, 2019) y en establecer criterios e indicadores que permitan el progreso hacia un manejo forestal sostenible (Aguirre-Calderón, 2015; Linser et al., 2018; Wear & Greis, 2013).

Finalmente, se prevé que las consecuencias directas e indirectas de la problemática planteada repercutirán en la población de México, por lo que las instituciones y tomadores de decisiones pertinentes deberían de reconocer la importancia que tienen los bosques, ya que contribuyen al bienestar humano en la regulación de los flujos de agua y aire, el suministro de alimentos, madera,

refugio, forraje, fibra, etcétera, además, generan ingresos, empleo y son vitales para la seguridad alimentaria de la humanidad, así como albergan gran parte de la biodiversidad (FAO, 2015; 2020). En síntesis, su protección y aprovechamiento sostenible deberían presentarse dentro de los objetivos básicos de las políticas públicas a nivel regional, nacional e internacional.

4.6 Conclusiones

Se logró utilizar las RNN-DLSTM y la técnica de los ciclos entrenamiento-proyección para proyectar ST a largo plazo. El estudio de ST a largo plazo son importantes dado que, una ST proyectada en poco más de 80 años, puede servir como guía a los tomadores de decisiones para el diseño y adecuación de políticas públicas incluyentes y responsables con el medio ambiente. Por lo tanto, es factible utilizar estos métodos para proyectar variables del sector forestal de México hasta el año 2100.

El sector forestal de México es modificado por varios y diversos factores internos y externos al país. Es muy probable que esta situación se presente en el largo plazo, tanto en México como en el mundo, dado el incremento en la población nacional e internacional, la falta de manejos forestales sostenibles adecuados a cada región y por la inadecuada instrumentación de la gobernanza ambiental. El capitalismo, la globalización, la pobreza, la lucha por control de los recursos naturales y la falta de datos precisos agravarán dicha problemática.

Se requiere de investigaciones dedicadas en aportar proyecciones periódicas del sector forestal mexicano. Además, como es un trabajo muy amplio, se sugiere utilizar otras variables clave del sector forestal, e incluso de otros sectores o áreas que se relacionan, como el sector agropecuario, el ámbito económico y social, además de extender el estudio a proyecciones multivariantes con RNN-DLSTM.

4.7 Literatura citada

- Adam, K., Smagulova, K., & James, A. P. (2018). Memristive LSTM network hardware architecture for time-series predictive modeling problems. *2018 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS)* (pp. 459-462). IEEE. doi:10.1109/APCCAS.2018.8605649
- Aguirre-Calderón, O. A. (2015). Manejo forestal en el siglo XXI. *Madera y bosques*, 21(SPE), 17-28.
- Ali, I., & Alharbi, O. M. (2020). COVID-19: Disease, management, treatment, and social impact. *Science of The Total Environment*, 728, 138861. doi:10.1016/j.scitotenv.2020.138861
- Alimba, C. G., & Faggio, C. (2019). Microplastics in the marine environment: Current trends in environmental pollution and mechanisms of toxicological profile. *Environmental toxicology and pharmacology*. 68, 61-74. doi:10.1016/j.etap.2019.03.001
- Appleyard, J., Kocisky, T., & Blunsom, P. (2016). Optimizing performance of recurrent neural networks on gpus. *arXiv e-prints*. arXiv:1604.01946.
- Bianchi, F. M., Maiorino, E., Kampffmeyer, M. C., Rizzi, A., & Jenssen, R. (2017). *Recurrent neural networks for short-term load forecasting: an overview and comparative analysis*. Edit. Springer Nature. Cham, Switzerland. doi:10.1007/978-3-319-70338-1
- Bloomberg Economics. (2020). Global \$6 trillion slump may be optimistic, economists warn. Recuperado el 1 de mayo del 2020, de <https://www.bloomberg.com/news/articles/2020-04-27/global-6-trillion-slump-may-be-optimistic-bloomberg-economics>
- Bonilla-Moheno, M., & Aide, T. M. (2020). Beyond deforestation: Land cover transitions in Mexico. *Agricultural Systems*, 178, 102734. doi:10.1016/j.agsy.2019.102734
- Brinkmann, R. (2020). Interconnections in Environmental Sustainability: Water and Energy. In R. Brinkmann (Ed.), *Environmental Sustainability in a Time of Change* (pp. 195-216). Cham, Switzerland: Palgrave Macmillan. doi:10.1007/978-3-030-28203-5_9
- Bucharova, A., & Krahulec, F. (2020). Native seed addition as an effective tool for post-invasion restoration. *Basic and Applied Ecology*, 43, 34-41. doi:10.1016/j.baae.2019.10.009
- Bush, M. J. (2020). *Climate Change and Renewable Energy: How to End the Climate Crisis*. In (pp. 421-475). Cham, Switzerland: Palgrave Macmillan. doi:10.1007/978-3-030-15424-0

- Chapela, G., & Merino P., L. (2019). Hacia una política forestal sustentable e incluyente. Los bosques de México, problemas y propuestas. En Merino P., L. (Ed.), *Crisis ambiental en México: ruta para el cambio* (163-189). UNAM. México.
- Chollet, F. (2018). *Deep Learning mit Python und Keras*. Edit. Manning Publications Co. Estados Unidos de América.
- CONAFOR. (2018). Inventario Nacional Forestal y de Suelos Informe de Resultados 2009-2014 (Primera ed.) [pdf]. Recuperado el 8 de abril del 2020, de <https://snigf.cnf.gob.mx/inventario-nacional-forestal/>
- Creutzig, F., d'Amour, C. B., Weddige, U., Fuss, S., Beringer, T., Gläser, A., ... & Edenhofer, O. (2019). Assessing human and environmental pressures of global land-use change 2000–2010. *Global Sustainability*, 2, artículo 1. doi:10.1017/sus.2018.15
- FAO. (2015). Evaluación de los recursos forestales mundiales 2015: Compendio de datos [pdf]. Recuperado el 8 de abril del 2020, de <http://www.fao.org/3/a-i4808s.pdf>
- FAO. (2016). Evaluación de los recursos forestales mundiales 2015: ¿Cómo están cambiando los bosques del mundo? (Segunda ed.) [pdf]. Recuperado el 8 de abril del 2020, de <http://www.fao.org/3/a-i4793s.pdf>
- FAO. (2019a). FAOSTAT [database]. Recuperado el 14 de enero del 2020, de <http://www.fao.org/faostat/es/#data>
- FAO (2019b). El estado de la seguridad alimentaria y la nutrición en el mundo 2019: Protegerse frente a la desaceleración y el debilitamiento de la economía [pdf]. En colaboración con: FIDA, OMS, PMA, & UNICEF. Roma, FAO. Recuperado el 28 de abril del 2020, de <http://www.fao.org/3/ca5162es/ca5162es.pdf>
- FAO. (2020). Evaluación de los recursos forestales mundiales 2020: Principales resultados [pdf]. Recuperado el 9 de mayo del 2020, de <http://www.fao.org/3/ca8753es/CA8753ES.pdf>
- Fandango, A. (2018). *Mastering TensorFlow 1. x: Advanced machine learning and deep learning concepts using TensorFlow 1. x and Keras*. Packt Publishing Ltd. Birmingham, Mumbai.
- Ferreira, L. N., Vega-Oliveros, D. A., Zhao, L., Cardoso, M. F., & Macau, E. E. (2020). Global Fire Season Severity Analysis and Forecasting. *Computers & Geosciences*, 134, artículo 104339. doi:10.1016/j.cageo.2019.104339
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669. doi:10.1016/j.ejor.2017.11.054
- Foley, J. A., Ramankutty, N., Brauman, K. A., Cassidy, E. S., Gerber, J. S., Johnston, M., ... & Balzer, C. (2011). Solutions for a cultivated planet. *Nature*, 478(7369), 337. doi:10.1038/nature10452

- Fraser, A. (2019). *Achieving the Sustainable Management of Forests*. Cham, Switzerland: Springer International Publishing. doi:10.1007/978-3-030-15839-2
- Goodell, J. W. (2020). COVID-19 and finance: Agendas for future research. *Finance Research Letters*, 101512. Prepublicación online. doi:10.1016/j.frl.2020.101512
- Graves, A. (2012). *Supervised sequence labelling*. In Supervised sequence labelling with recurrent neural networks (pp. 5-13). Springer, Berlin, Heidelberg. doi:10.1007/978-3-642-24797-2
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*, 18(5-6), 602-610. doi:10.1016/j.neunet.2005.06.042
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232. doi:10.1109/TNNLS.2016.2582924
- Gryazkin, A., Bepalova, V., Samsonova, I., Belyaeva, N., & Belyaev, V. (2019, August). Potential reserves and development of non-wood forest resources. *IOP Conference Series: Earth and Environmental Science*, 316(1), Artículo 12007. doi:10.1088/1755-1315/316/1/012007
- Gulli, A., & Pal, S. (2017). *Deep learning with Keras: Implement neural networks with Keras on Theano and TensorFlow*. Edit. Packt Publishing Ltd. Birmingham, Inglaterra.
- Harrison, R. M. (2014). *Pollution: causes, effects and control* (5ta ed). Royal Society of Chemistry
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. doi:10.1162/neco.1997.9.8.1735
- Huang, C., Wang, Y., Li, X., Ren, L., Zhao, J., Hu, Y., ... & Cheng, Z. (2020). Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. *The lancet*, 395(10223), 497-506. doi:10.1016/S0140-6736(20)30183-5
- Kurumatani, K. (2018). Time Series Prediction of Agricultural Products Price Based on Time Alignment of Recurrent Neural Networks. *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 81-88). IEEE. doi:10.1109/ICMLA.2018.00020.
- Levendis, J. D. (2018). *Time series econometrics: Learning through replication*. Springer International Publishing. Switzerland. doi:10.1007/978-3-319-98282-3
- Liang, H., Zhang, M., & Wang, H. (2019). A Neural Network Model for Wildfire Scale Prediction Using Meteorological Factors. *IEEE Access*, 7, 176746-176755. doi:10.1109/ACCESS.2019.2957837

- Linser, S., Wolfslehner, B., Bridge, S., Gritten, D., Johnson, S., Payn, T., Prins, K., Raši, R., & Robertson, G. (2018). 25 Years of Criteria and Indicators for Sustainable Forest Management: How Intergovernmental C&I Processes Have Made a Difference. *Forests*, 9(9), Artículo 578. doi:10.3390/f9090578
- Liu, D., Guo, X., & Xiao, B. (2019). What causes growth of global greenhouse gas emissions? Evidence from 40 countries. *Science of The Total Environment*, 661, 750-766. doi:10.1016/j.scitotenv.2019.01.197
- Lorenz, U., Sverdrup, H. U., & Ragnarsdottir, K. V. (2018). Global Megatrends and Resource Use—A Systemic Reflection. In H. Lehmann (Ed.), *Factor X: Challenges, Implementation Strategies and Examples for a Sustainable Use of Natural Resources* (Vol. 32). (pp. 31-43). Cham, Switzerland: Springer International Publishing. doi:10.1007/978-3-319-50079-9_3
- Lorenzen, M., Orozco-Ramírez, Q., Ramírez-Santiago, R., & Garza, G. G. (2020). Migration, socioeconomic transformation, and land-use change in Mexico's Mixteca Alta: Lessons for forest transition theory. *Land Use Policy*, 95, 104580. doi:10.1016/j.landusepol.2020.104580
- Meadows, D. H., Meadows, D. L., Randers, J., & Behrens III, W. W. (1972). *The Limits to growth: a report for the Club of Rome's project on the predicament of mankind*. Club of Rome. New York: Universe Books
- Menezes-Silva, P. E., Loram-Lourenço, L., Alves, R. D. F. B., Sousa, L. F., Almeida, S. E. D. S., & Farnese, F. S. (2019). Different ways to die in a changing world: Consequences of climate change for tree species performance and survival through an ecophysiological perspective. *Ecology and evolution*, 9(20), 11979-11999. doi:10.1002/ece3.5663
- Mondal, B., Saha, A. K., & Roy, A. (2019). Mapping mangroves using LISS-IV and Hyperion data in part of the Indian Sundarban. *International Journal of Remote Sensing*, 40(24), 9380-9400. doi:10.1080/01431161.2019.1630784
- Monterroso, A., & Conde, C. (2015). Exposure to climate and climate change in Mexico. *Geomatics, Natural Hazards and Risk*, 6(4), 272-288. doi:10.1080/19475705.2013.847867
- Monjarás-Vega, N. A., Briones-Herrera, C. I., Vega-Nieva, D. J., Calleros-Flores, E., Corral-Rivas, J. J., López-Serrano, P. M., ... & Alvarado-Celestino, E. (2020). Predicting forest fire kernel density at multiple scales with geographically weighted regression in Mexico. *Science of The Total Environment*, 718, 137313. doi:10.1016/j.scitotenv.2020.137313
- Newbold, T., Hudson, L. N., Hill, S. L., Contu, S., Lysenko, I., Senior, R. A., Börger, L., Bennett, D. J., Choimes, A., Collen, B., Day, J., Palma, A. D., Díaz, S., Echeverria-Londoño, J., Edgar, M. J., Feldman, A., Garon, M., Harrison, M. L. K., Alhousseini, T., ... & Day, J. (2015). Global effects of land use on local terrestrial biodiversity. *Nature*, 520(7545), 45-50. doi:10.1038/nature14324

- NVIDIA. (2020). NVIDIA cuDNN. Recuperado el 16 de abril del 2020, de <https://developer.nvidia.com/cudnn>
- OECD. (2012). OECD environmental outlook to 2050: The consequences of inaction. Organization for Economic Co-operation and Development Staff [pdf]. *OECD Publishing*. doi:10.1787/9789264122246-en
- OMS. (2020). Coronavirus disease (COVID-19): Situation Report-126 [pdf]. Recuperado el 25 de mayo del 2020, de https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200525-covid-19-sitrep-126.pdf?sfvrsn=887dbd66_2
- ONU. (2019). World Population Prospects 2019. Recuperado el 15 de abril del 2020, de <https://population.un.org/wpp/DataQuery/>
- PwC UK. (2017). Una mirada al futuro: ¿Cómo cambiará el orden económico mundial para el 2050? [pdf]. Recuperado el 8 de abril del 2020, de https://www.pwc.com/co/es/assets/document/el_mundo_en_2050.pdf
- Sagheer, A., & Kotb, M. (2019). Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing*, 323, 203-213. doi:10.1016/j.neucom.2018.09.082
- Samarawickrama, A. J. P., & Fernando, T. G. I. (2017). A recurrent neural network approach in predicting daily stock prices an application to the Sri Lankan stock market. *2017 IEEE International Conference on Industrial and Information Systems (ICIIS)*. Peradeniya. (pp. 1-6). IEEE. doi:10.1109/ICIINFS.2017.8300345
- Santana, J. R. H., Manent, M. B., Linares, A. P. M., Delhumeau, E. O., Zorrilla, M., & Hernández, A. O. (2020). Aptitud sectorial para el desarrollo forestal: consideraciones en la ordenación general del territorio mexicano. *Cuadernos geográficos de la Universidad de Granada*, 59(1), 32-53. doi:10.30827/cuadgeo.v59i1.8079
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117. doi:10.1016/j.neunet.2014.09.003
- SEMARNAT. (2020). Anuario estadístico de la producción forestal 2017 [pdf]. Recuperado el 29 de marzo del 2020, de <http://www.fao.org/3/ca8753es/CA8753ES.pdf>
- Sharma, S., MacKenzie, R. A., Tieng, T., Soben, K., Tulyasuwan, N., Resanond, A., ... & Litton, C. M. (2020). The impacts of degradation, deforestation and restoration on mangrove ecosystem carbon stocks across Cambodia. *Science of The Total Environment*, 706, artículo 135416. doi:10.1016/j.scitotenv.2019.135416
- Sheppard, J. P., Chamberlain, J., Agúndez, D., Bhattacharya, P., Chirwa, P. W., Gontcharov, A., ... & Mutke, S. (2020). Sustainable Forest Management Beyond the Timber-Oriented Status Quo: Transitioning to Co-production of Timber and Non-wood Forest Products—a Global Perspective. *Current Forestry Reports*, 1-15. doi:10.1007/s40725-019-00107-1

- Siry, J. P., Cabbage, F. W., Potter, K. M., & McGinley, K. (2018). Current perspectives on sustainable forest management: North America. *Current Forestry Reports*, 4(3), 138-149. doi:10.1007/s40725-018-0079-2
- Steffen, W., Broadgate, W., Deutsch, L., Gaffney, O., & Ludwig, C. (2015). The trajectory of the Anthropocene: the great acceleration. *The Anthropocene Review*, 2(1), 81-98. doi:10.1177/2053019614564785
- Trujillo-Miranda, A. L., Toledo-Aceves, T., López-Barrera, F., & Günter, S. (2020). Tree diversity and timber productivity in planted forests: *Pinus patula* versus mixed cloud forest species. *New Forests*, 1-19. doi:10.1007/s11056-020-09787-1
- Wear, D. N., & Greis, J. G. (2013). The southern forest futures project: Technical report. (Gen. Tech. Rep. SRS-GTR-178) [pdf]. Asheville, NC: USDA-Forest Service, Southern Research Station. Recuperado el 29 de marzo del 2020, de https://www.srs.fs.fed.us/pubs/gtr/gtr_srs178.pdf
- Whitmee, S., Haines, A., Beyrer, C., Boltz, F., Capon, A. G., de Souza Dias, B. F., ... & Horton, R. (2015). Safeguarding human health in the Anthropocene epoch: report of The Rockefeller Foundation–Lancet Commission on planetary health. *The Lancet*, 386(10007), 1973-2028. doi:10.1016/S0140-6736(15)60901-1

5 CONCLUSIONES GENERALES

Se logró diseñar una arquitectura única para cada una de las variables clave del sector forestal mexicano: producción, importación y exportación forestal maderable y la superficie arbolada de México. Por lo que fue posible trabajar, en Python, las redes neuronales recurrentes LSTM de aprendizaje profundo para obtener cada una de las proyecciones anuales, realizadas hasta el año 2100. El error calculado para cada entrenamiento fue aceptable, lo cual es un aporte a las posibles investigaciones futuras que tengan como objetivo proyectar series de tiempo en el largo plazo.

El estudio del sector forestal de México y el mundo, arrojó una incertidumbre en la pérdida de la superficie forestal y una degradación de los bosques del mundo a causa de la acción antropogénica de los países en desarrollo, con un índice de pobreza alto. Un caso de ejemplo evidente es México, con poco menos de la mitad de su población en situación de pobreza y una explotación forestal sin manejos forestales sostenibles adaptados a cada región, debido a la producción y venta de madera ilegal.

Hasta el año 2100 se estima que, se continuará con la pérdida de la superficie forestal arbolada, hasta llegar a una pérdida estimada de cerca de 6 millones de ha, si se sigue la tendencia observada en los datos históricos desde 1990 y, en especial, si se sigue con las mismas acciones antropogénicas. Este futuro posible, puede cambiar si se emplean políticas públicas y ambientales eficientes, que promuevan la conservación y la producción con manejos sostenibles. Además, se debería considerar el tomar decisiones a largo plazo, pensando en el beneficio colectivo de las generaciones futuras, y no solo en los beneficios inmediatos e individuales que se observó en el pasado y presente.

Por su parte la producción y la exportación presentarán altibajos marcados. La producción, podría mantenerse relativamente constante hasta llegado el año 2100, lo que se estima cambie si no se controla la deforestación ilegal y la pérdida de superficie forestal arbolada por el cambio de uso de suelo, los incendios, entre

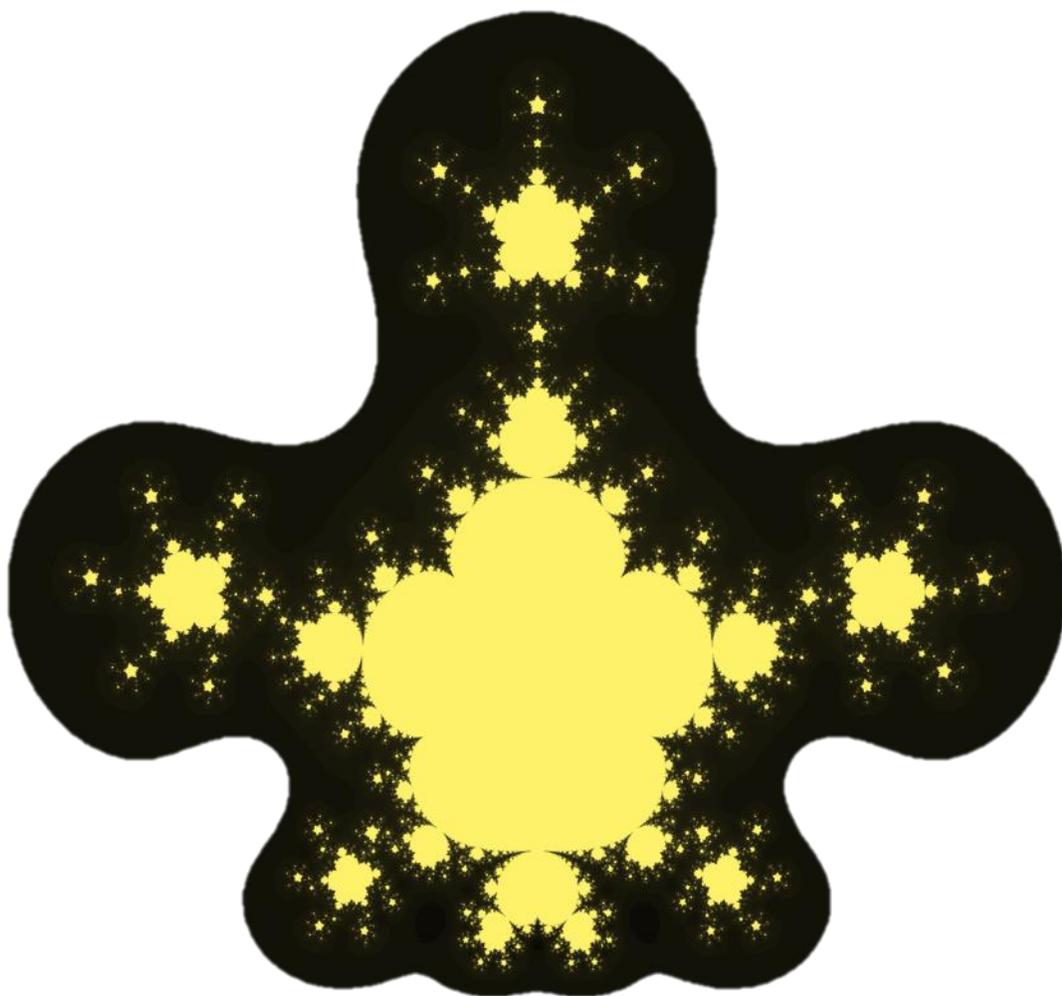
otros. Por lo tanto, si se desea un futuro positivo, que presente los mayores beneficios sociales, económicos y ambientales, es menester continuar con investigaciones que aporten datos y proyecciones periódicas a largo plazo.

Lo anterior permitirá mejorar la toma de decisiones en el presente para orientar el futuro. Con esto se concluye que, las proyecciones elaboradas en la presente investigación no son el futuro exacto que se vivirá, ni se pretende alcanzar tan imposible objetivo, sino que se reconoce la importancia que tienen las proyecciones para la toma de decisiones y que se infiera que el futuro se construirá con cada una de las acciones que se sigan tomando con el paso del tiempo. Por lo que no se deben de aceptar las proyecciones como una ley universal o exacta.

Se recomienda mejorar los métodos utilizados para el muestreo, la recopilación y publicación de los datos referentes al sector forestal de México y el mundo. Debido a que en la actualidad las investigaciones, gobernanza ambiental y la toma de decisiones requieren de bases de datos actualizadas, periódicas y con mayor precisión, para obtener proyecciones y análisis de datos más completos y confiables. El avance en las tecnologías y la, cada vez más, eficiencia en los métodos para medir las variables del sector forestal, serán las herramientas que mejoren el aporte de datos actualizados de los bosques del mundo.

Finalmente, se continuará con esta investigación, al utilizar, en futuras proyecciones, métodos híbridos de aprendizaje profundo, es decir, una combinación de tipos de redes neuronales artificiales y otros métodos modernos relacionados con la inteligencia artificial.

Fin de esta obra



El futuro es un fractal...

Si los conoces,

lo entenderás.

