

Modelo de la productividad primaria neta aérea (PPNA) en función de la precipitación y temperatura mensual para pastizales de Corrientes

*Trabajo final presentado para optar al título de
Especialista en Teledetección y Sistemas de Información Geográfica aplicados
al estudio de los recursos naturales y la producción agropecuaria*

Andrés Alejandro Leszczuk
Ingeniero Forestal-Facultad de Ciencias Forestales
Universidad Nacional de Misiones - 2017

Lugar de trabajo: Facultad de Ciencias Forestales, UNaM



Escuela para Graduados Ing. Agr. Alberto Soriano
Facultad de Agronomía, Universidad de Buenos Aires



TUTOR

Mariano Oyarzabal
Ingeniero Agrónomo (EPG – FAUBA)
Doctor en Ciencias Agropecuarias (EPG – FAUBA)

JURADO DE TRABAJO FINAL

Jurado
Pablo Baldassini
Licenciado en Ciencias Ambientales (FAUBA)
Doctor en Ciencias Agropecuarias (EPG – FAUBA)

Jurado
Maria Mercedes Vasallo
Ingeniero Agrónomo (FAUBA)
Doctor en Ciencias Agropecuarias (EPG – FAUBA)

Fecha de defensa del Trabajo Final: 16 de diciembre de 2020

Agradecimientos

Agradezco a todos los que formaron parte de esta comfortable etapa de mi vida

INDICE GENERAL

INDICE FIGURAS Y TABLAS.....	5
1 RESUMEN	6
2 ABSTRACT.....	7
3 INTRODUCCIÓN	8
4 MATERIALES Y MÉTODOS.....	12
4.1 Área de estudio.....	12
4.2 Mapa de suelos del INTA.....	13
4.3 Datos climáticos	14
4.4 Estimación de la fRFAA mediante el índice de vegetación normalizado (IVN) de MODIS	15
4.5 Análisis de datos y ajuste de modelos	16
5 RESULTADOS	18
6 DISCUSIÓN	21
7 CONCLUSIONES.....	22
8 REFERENCIAS BIBLIOGRÁFICAS	23

INDICE FIGURAS Y TABLAS

Figura 1: Mapa general de ubicación y disposición de los potreros seleccionados para este estudio.	13
Figura 2: Mapa de suelos de INTA EEA Mercedes. Se observan los taxones de suelo, los potreros seleccionados y la grilla de pixeles MODIS.....	14
Tabla 1: Coeficientes del ajuste del modelo para estimación de la PPNA para campos naturales en Corrientes.....	19
Figura 3: Relación lineal entre los valores observados de PPNA y los valores predichos de PPNA mediante el modelo ajustado por potrero.	19
Figura 4: Relación lineal entre los valores predichos y observados de PPNA para todo el conjunto de datos.....	20

Modelo de la productividad primaria neta aérea (PPNA) en función de la precipitación y temperatura mensuales para pastizales de Corrientes

RESUMEN

En la provincia de Corrientes la ganadería es una de las actividades económicas más importantes. Allí, los pastizales aportan la mayor parte del forraje consumido por el ganado. Entonces, conocer y predecir la productividad de los pastizales es clave. Actualmente es posible estimar la productividad primaria neta aérea (PPNA) a partir de imágenes satelitales por medio de índices espectrales, con paso diario y a escala de potrero. Al relacionar la PPNA con variables ambientales es posible desarrollar modelos de predicción. El objetivo de este trabajo fue desarrollar un modelo que permita predecir la PPNA a partir de datos meteorológicos y tipos de suelo en el sureste correntino. La descarga y análisis de información se realizó con la plataforma Google Earth Engine (GEE), y los modelos fueron realizados en software R mediante modelos lineales mixtos. Se logró ajustar un modelo único que explica hasta un 64% la variabilidad de la PPNA mensual en función de las precipitaciones y temperaturas del aire medias mensuales. El modelo es un aporte a la cadena de la carne correntina, porque le brinda al productor una herramienta de anticipación y soporte para la toma de decisiones de manejo.

Palabras Clave: PPNA, modelos lineales mixtos, MODIS, GEE, R

Aboveground of the net primary productivity model (ANPP) as a function of monthly rainfall and temperature for grasslands in Corrientes

ABSTRACT

Livestock production is one of the most important economic activities in Corrientes province. There, grasslands provide most of the forage consumed by cattle. Thus, to know and to predict grasslands productivity is key. It is currently possible to estimate aboveground net primary productivity (ANPP) from spectral indices provided by satellite images. It is possible to develop models that predict grasslands ANPP from weather data. The objective was to develop a prediction model of ANPP from meteorological and quality site data in the southeast of Corrientes province. Data downloads and analysis were performed on the Google Earth Engine (GEE) platform. The models were made in R software using mixed linear models. A unique model was fitted that explains up to 64% of the variability of the monthly ANPP as a function of precipitation and air temperature. The model is a contribution to the Corrientes' meat chain, it provides the farmers with a tool to anticipate and support management decisions.

Key words: NPP, mixed linear models, MODIS, GEE, R.

1 INTRODUCCIÓN

La ganadería en la provincia de Corrientes se basa principalmente en la utilización de forraje proveniente de pastizales naturales. Existe unas 5.740.000 ha de pastizales disponibles para la explotación ganadera, con productividades que van desde los 3500 a 6500 kilogramos de materia seca por hectárea por año ($\text{kg MS ha}^{-1} \text{ año}^{-1}$), concentrados principalmente en la época estival (Pizzio et al., 2016). Para el correcto desarrollo de la actividad ganadera se requiere conocer la productividad forrajera. Esta productividad, en ocasiones, se denomina tasa de crecimiento del forraje y está directamente relacionada con la productividad primaria neta aérea (PPNA) (Oesterheld et al., 2014). La PPNA, es un componente clave para determinar la carga animal (Oesterheld et al., 2014; Grigera et al., 2007). Poder predecir la PPNA constituye una herramienta de soporte a la decisión que permite establecer la carga (Bork y Werner, 1999), conociendo anticipadamente los déficits y excesos de forraje (Paruelo et al., 2010). La estimación de la PPNA es un paso crítico en el manejo de los recursos forrajeros. Sin embargo, para que esta información tenga impacto en los sistemas ganaderos tiene que, en primer lugar, estar disponible para técnicos y productores rápidamente y, en segundo lugar, deben existir herramientas de soporte, para que esta información pueda traducirse en decisiones de manejo (Paruelo et al., 2010).

Existen dos formas principales de estimar la PPNA. Los métodos basados en cortes sistemáticos o por medio del uso modelos de simulación forrajeros (Graux et al., 2011; Li et al., 2011), poseen limitaciones en tiempo y económicas. Además, la variabilidad estacional e interanual de la PPNA de los recursos forrajeros requieren de un muestreo exhaustivo a lo largo del tiempo si se desea obtener fiabilidad en los datos (Bork & Werner, 1999; Grigera et al., 2007). Alternativamente, el modelo eco-fisiológico propuesto por Monteith (1972) puede ser utilizado como opción para determinar la PPNA. Este modelo establece que la PPNA (en $\text{kg MS ha}^{-1} \text{ mes}^{-1}$) está determinada por la cantidad de radiación fotosintéticamente activa absorbida (RFAA) por los tejidos de las plantas ($\text{MJ mes}^{-1} \text{ ha}^{-1}$) y la eficiencia con que dicha radiación es transformada en materia seca, que es la Eficiencia del Uso de Radiación (EUR, en kg MS MJ^{-1}). La PPNA se estima mediante la siguiente ecuación:

$$\text{PPNA (kg MS ha}^{-1} \text{ mes}^{-1}) = \text{RFAA (MJ mes}^{-1} \text{ ha}^{-1}) * \text{EUR (kg MS MJ}^{-1})$$

La RFAA es el producto entre la radiación fotosintéticamente activa incidente (RFA), obtenida de estación meteorológica o a partir de sensores remotos, y la fracción de dicha radiación que es interceptada por los tejidos vivos (fRFA). La fRFA puede ser estimada con razonable precisión a partir de teledetección y esa relación es el vínculo entre la productividad forrajera y los sensores remotos (Paruelo et al., 2010, Romero-Sanchez & Ponce-Hernandez, 2017). El índice de vegetación normalizado (IVN o NDVI, por sus siglas en inglés) y el índice de vegetación mejorado (IVM o EVI, por sus siglas en inglés) pueden explicar en gran medida el estado de las coberturas vegetales, que depende de la cantidad y disposición espacial del área foliar. Posee innumerables aplicaciones en ecología, silvicultura, ganadería, entre otras, siendo muy utilizado para determinación de la fRFA (Paruelo et al., 2010). Hasta hace pocos años, la teledetección de la fRFA de forma continua en el tiempo y a nivel de lote estuvo limitada por la baja resolución espacial o temporal de los sensores que existían en el momento (AVHRR/NOAA o Landsat). Sin embargo, la aparición del sensor MODIS (Moderate Resolution Imaging Spectroradiometer) a bordo de los satélites Terra y Aqua permite el seguimiento de la PPNA forrajera (e.g. Grigera et al. 2007; Paruelo et al., 2010), ya que cuenta con un producto de una resolución temporal de 16 días y una resolución espacial de 5,3 ha.

Además de las características propias de cada de cada tipo de pastizal, la PPNA está influenciada directamente por las condiciones climáticas. Las precipitaciones limitan el crecimiento y la temperatura promueve de forma directa la producción hasta cierto punto, pero la inhibe de forma indirecta al aumentar el déficit hídrico del suelo (Usandivaras, 2006). El conocimiento de los controles de la PPNA, que determinan la magnitud y dirección de los cambios temporales, puede ayudar a la toma de decisiones de manejo y determinar los resultados de los sistemas ganaderos, mediante: análisis de campaña ganadera, a partir de la incorporación de producción forrajera (antes inexistente o muy indirecta); balance y presupuesto forrajero, a partir de la información de producción forrajera específica para establecimientos determinados; decisiones de corto plazo sobre ocupación de lotes, por medio de la determinación del tiempo de ocupación del ganado para un determinado escenario de biomasa remanente a dejar.

La relación entre las precipitaciones y la PPNA ha sido ampliamente utilizada para describir la variabilidad forrajera tanto a nivel de pequeños sitios como en grandes extensiones (Lauenroth & Sala, 1992). El agua disponible para las plantas se almacena en

los estratos superiores de suelo. Los suelos arcillosos, con buenas características estructurales, poseen una mayor capacidad de almacenamiento, permitiendo mayor disponibilidad de agua para el crecimiento forrajero. Para la producción del año en curso, el agua almacenada incluye precipitaciones desde el final del ciclo ganadero del año anterior hasta el final del ciclo productivo actual. Este concepto se denomina precipitaciones de “año de cosecha” (Patton et al., 2007), y es el que relaciona a las precipitaciones y el tipo de suelo con la capacidad de retención de agua y productividad del forraje. Y se encuentra influenciado por las precipitaciones ocurridas en el ciclo anterior, es decir si años con suficientes precipitaciones a final de ciclo productivo puede afectar positivamente la siguiente temporada productiva. En su estudio Lauenroth & Sala (1992) analizaron la relación entre las precipitaciones y la productividad forrajera durante 52 años, logrando estimar modelos que explicaban entre el 39 y 49% de la variabilidad de la producción forrajera. Por su parte Patton et al. (2007) encontraron diferencias significativas entre distintas intensidades de pastoreo y precipitaciones medidas a finales de ciclos productivos como cm de lámina de agua, determinando que pastoreos intensivos aumentan la evapotranspiración y escorrentía.

Además de las precipitaciones y tipo de suelo, las temperaturas son un tercer factor a tener en cuenta. La mayor parte de los vegetales no pueden crecer por debajo de los 0°C, sin embargo, la mayoría de los estudios no ha encontrado una relación lineal fuerte entre las temperaturas y la producción o una correlación negativa entre ambas, aunque el desarrollo morfológico de las plantas está principalmente controlado por dichos factores (Patton et al., 2007). Las especies presentan distintas temperaturas óptimas de crecimiento y se pueden agrupar según grupos funcionales en especies C₄, con un óptimo a mayores temperaturas, y en especies C₃ con una temperatura óptima inferior. En regiones tropicales, donde predominan las especies C₄, y en suelos con suficiente agua, la PPNA aumenta linealmente hasta los 32 °C de temperatura, disminuyendo su crecimiento a partir de dicha temperatura. Es así que Li et al. (2011) describen en Nueva Zelanda que la PPNA de pasturas con o sin riego, es cero a temperaturas mayores a 35°.

A escala regional, en el sureste Correntino, se ha observado una interacción entre las temperaturas y precipitaciones: en determinados rangos de precipitaciones (menores a 50 mm mensuales), la PPNA declina linealmente al aumentar la temperatura media anual como consecuencia del aumento de la evapotranspiración del suelo (Usandivaras, 2006). Por otro lado, Smoliak (1956) logró desarrollar un modelo predictivo de forraje en

función a las precipitaciones acumuladas de mayo y junio para predecir la producción forrajera de especies como: *Stipa comata*, *Agropyron smithii* y *Koeleria cristata* de distintos campos experimentales en el suroeste de Alberta, Estados Unidos, con ajustes de hasta un 85%. Por otro lado, Wiles et al. (2011) estudiaron el efecto de la precipitación de primavera como un estimador de la PPNA de pasturas en Estados Unidos. La precipitación acumulada de los meses de abril, mayo y junio podrían explicar entre el 74 y 80% de la variación de la PPNA, ajustando un modelo de dos etapas (parte lineal y constante) que podría utilizarse como herramienta de soporte a las decisiones para técnicos y ganaderos. Martín et al. (2011) ajustando modelos de productividad de PPNA lograron determinar que el 72% de la variabilidad era explicada por medio de las precipitaciones y el tipo de pastizal analizado, encontrando que las temperaturas medias no presentaron significancia estadística, en pastizales templados de la provincia de Santa Fe, Argentina.

Si bien existen antecedentes de modelos de PPNA en función a las precipitaciones o temperaturas, aún no están disponibles modelos que integren ambas variables ambientales, u otras del tipo espacial y temporal en un mismo modelo. En la provincia de Corrientes existen estudios sobre PPNA para pastizales (Bedersky et al., 2017; Pizzio, 2014; Pizzio et al., 2016; Usandivaras, 2006), pero no existen modelos integradores que sirvan como herramienta para la toma de decisiones de los productores ganaderos.

2 MATERIALES Y MÉTODOS

2.1 Área de estudio

El área de estudio pertenece a la estación experimental agrícola (EEA) del INTA Mercedes (29°12'00" S, 58°05'00" O), vecina a la ciudad homónima de la provincia de Corrientes. De acuerdo con la taxonomía de suelos de USDA y a un relevamiento del INTA, los suelos son Argiudoles vérticos, un suelo de tipo loess, de arenisca en condiciones de humedad con un horizonte compuesto en su mayoría de arcilla en expansión. Las precipitaciones medias anuales son de 1478 mm, con una alta variabilidad interanual en el rango de los 758 a 2263mm. Las temperaturas medias mensuales van en el rango de 13,8 °C en los meses de julio a 25,4°C para enero. La vegetación de la región en la que se encuentra es descripta como una sábana herbácea con gramíneas megatérmicas o mesotérmicas (Oyarzabal et al., 2018). A nivel de paisaje, es caracterizado por la presencia de parches dominados por especies altas y bajas, cubre una superficie de 50.000 km², incluyendo el norte de Argentina, Uruguay y Brasil (Pizzio et al., 2016). El área de la EEA INTA Mercedes posee sesenta potreros, con una superficie total de 2050 ha. Del total de potreros, fueron seleccionados cinco, potreros con pastizales naturales y que no cambiaron su uso durante el período de estudio. En la figura 1 se observa la ubicación, disposición y los potreros seleccionados para este estudio.




Figura 1. Mapa general de ubicación y disposición de los potreros seleccionados para este estudio. **A** Muestra el campo experimental de la EEA INTA Mercedes y los potreros seleccionados para dicho estudio (en color naranja). **B** Ubicación de la Provincia de Corrientes, **C** Ubicación de la EEA dentro del departamento Mercedes en la Provincia de Corrientes

2.2 Mapa de suelos del INTA

Con el propósito de identificar y caracterizar los suelos en la provincia, el INTA cuenta con cartografía de suelos con escalas 1:50.000 (INTA, 2018). Esto permitió analizar si existe una relación entre el tipo de suelo y la PPNA. Los sub-grupos de suelos analizados fueron: Argiudol acuico, Argiudol típico, Distriudept lítico, Endoacuol típico, Epicuulf umbrico, Epicuert típico, Hapludalf acuolico, Hapludalf albacuico, Psamacient humacueptico. En la figura 2 se puede observar los cinco potreros para este estudio y la variabilidad de los sub-grupos de suelo para el primer tipo de clasificación descripto por INTA.

Los suelos del área de estudio se destacan por ser arcillosos con una buena retención de agua, con un horizonte Bt (Horizonte “B” textural) compacto que impide la profundización de raíces más allá de los 30 cm (Usandivaras, 2006). En otros sectores se caracterizan por poseer afloramiento rocoso en superficie, limitando el crecimiento de las pasturas debido a la baja retención hídrica.

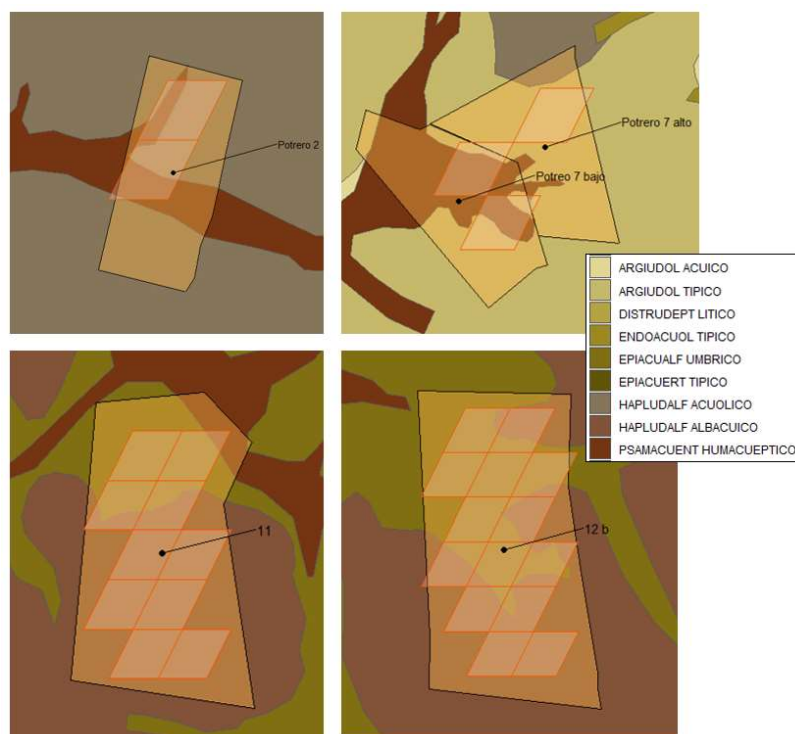


Figura 2. Croquis del área de estudio, donde se observan los potreros seleccionados de la EEA INTA Mercedes. De fondo se muestran los taxones de suelo en color (INTA, 2016) y la grilla de pixeles MODIS seleccionados.

2.3 Datos climáticos

Con el objetivo de analizar la relación entre las precipitaciones y la variabilidad de la PPNA se utilizó una serie de datos climáticos obtenidas de distintos sensores satelitales y estaciones meteorológicas:

Las precipitaciones fueron obtenidas del sensor TRMM, producto 34B2, de precipitaciones estimadas cada tres horas (Adler et al., 2003), datos generados por sensores activos (microondas) en distintos satélites meteorológicos (SSMI, SSMIS, MHS, AMSU-B y AMSR-E) y disponibles en altas resoluciones temporales (cada hora) pero en baja resolución espacial (pixel de $>0.25^\circ$ lado). Todos los datos fueron descargados mediante un Script generado en Google Earth Engine, para la serie temporal 2000 a 2018. Para toda la superficie de estudio fueron descargados datos de un pixel multiplicado por 24 horas y por el número de días que correspondía a cada mes, para obtener el valor de precipitación mensual promedio.

Las temperaturas del aire máximas y mínimas medias mensuales para el periodo 2000 a 2018, fueron obtenidas de estación experimental mediante el acceso al servicio

pago WS (<https://weather.mdaus.com>), servidor de datos climáticos, que cuenta con el acceso a la información de la estación experimental ubicada en el aeropuerto de la localidad de Paso de los libres, ubicada a 80 km de la EEA.

2.4 Estimación de la fRFA mediante el índice de vegetación normalizado (IVN) de MODIS

Los valores de fRFA para la estimación de la PPNA mediante la ecuación de Monteith (1972), fueron generados mediante el índice de vegetación normalizada (IVN) del sensor MODIS para el período 2000 a 2018. La descarga se realizó mediante la plataforma GEE. MODIS genera un producto de índice de vegetación normalizada cada 16 días denominado MOD13Q1, disponible con una resolución espacial de 250 metros (tamaño de pixel de 5,3 ha). Este producto es ampliamente utilizado en estudios de coberturas vegetales, con muchos ejemplos en estimaciones de PPNA en sistemas pastoriles (Baldassini et al., 2012; Grigera et al., 2007; J. Paruelo et al., 2010; entre otros).

En la figura 2 se observa la grilla de distribución de los pixeles MODIS seleccionados para determina el IVN. Si bien la mayoría de los pixeles ingresan de forma completa dentro de los potreros, fueron seleccionados pixeles con más del 90% de superficie dentro de los polígonos para aumentar el número de datos por potreros. Un claro ejemplo se observa en el “Potrero 2”, donde solamente posee un pixel puro completo, y se agregó uno más para descargar información satelital.

Los valores de IVN, fueron descargados solamente para potreros con pastizales naturales, es decir, fueron descartados aquellas superficies con alguna cobertura diferente (pasturas implantadas o coberturas agrícolas), en cualquier año durante el período 2000 a 2018. A partir del modelo de Grigera et al. (2007), se transformaron los datos de IVN a fRFA (ecuación 1).

La radiación fotosintéticamente activa incidente (RFA) fue obtenida a partir de valores de radiación incidente total publicados por NASA (<https://power.larc.nasa.gov/data-access-viewer>) a partir del satélite MERRA-2 (Stackhouse et al., 2016). Debido a que solamente el 48% de esta radiación es utilizada por la vegetación para la producción de materia seca, estos datos fueron afectados por un

coeficiente de 0,48. Esta información posee una resolución de 0,5° de resolución espacial, y es suministrada diariamente.

Una vez obtenidos los datos de fRFA y RFA fue estimada la radiación fotosintéticamente activa absorbida o RFAA, para cada pixel dentro de cada potrero seleccionado, mediante la siguiente ecuación (1):

$$\text{RFAA [MJ mes}^{-1} \text{ ha}^{-1}] = 0.48 \times \text{RFA [MJ mes}^{-1} \text{ ha}^{-1}] \times \text{fRFA} \quad (1)$$

Posteriormente la estimación de la productividad primaria neta aérea se realizó aplicando el modelo lineal empírico propuesto por Grigera et al. (2007) mediante la siguiente ecuación:

$$\text{PPNA [kg MS mes}^{-1} \text{ ha}^{-1}] = 0.545 [\text{kg MS mes}^{-1} \text{ ha}^{-1}] + 0.323 [\text{kg MS mes}^{-1} \text{ ha}^{-1} / \text{MJ mes}^{-1} \text{ ha}^{-1}] \times \text{RFAA [MJ mes}^{-1} \text{ ha}^{-1}] \quad (2)$$

Donde PPNA es la productividad primaria neta aérea, como tasa en kg MS mes⁻¹ ha⁻¹ y RFAA es la radiación fotosintéticamente activa absorbida por la vegetación como MJ.m⁻². mes⁻¹ ha⁻¹.

2.5 Análisis de datos y ajuste de modelos

El análisis de datos estuvo orientado a ajustar un único modelo que permita predecir la PPNA en función de variables ambientales a escala de pixel MODIS (variable respuesta). El análisis estadístico, los gráficos y mapas fueron realizado mediante software R (R Core Team, 2019).

Fueron ajustados diferentes modelos lineales mixtos utilizando la metodología descrita por (Zuur et al., 2009). Como variables predictoras se seleccionaron las precipitaciones del sensor TRMM, la temperatura promedio obtenida de la estación meteorológica, los sub-grupos de suelo clasificados por INTA y el mes. Aquellas variables que no presentaban distribución normal fueron transformadas por medio del logaritmo natural (ln). Para el modelo se seleccionaron como efectos fijos las variables antes mencionadas y sus interacciones, y en los efectos aleatorios fueron ajustados los Potreros. Esto permitió ajustar al modelo todas las combinaciones de cargas de animales y manejos de forma aleatoria. Se utilizaron modelos mixtos debido a que permiten evaluar y ajustar datos que no cumplen con la independencia de datos.

Luego de ajustar varios modelos mediante la función “lme” descrita por Bates et al. (2018), se seleccionó un único modelo mediante ANOVA entre modelos. En primer lugar, solamente se escogieron aquellas variables que resultaron significativas con p valor $<0,05$. El modelo seleccionado mediante ANOVA fue el que presento menor valor de los índices estadísticos BIC y AIC, y el mayor valor de Pseudo R^2 .

3 RESULTADOS

El modelo seleccionado para predecir la PPNA en función de la precipitación y temperatura de pastizales del sur de Corrientes es el siguiente (ecuación 3):

$$\ln(\text{PPNA})_{ij} = \beta_0 + \beta_1 \cdot \ln(P) \times \text{Mes}_j + \beta_2 \times T \times \text{Mes}_j + \alpha \times \text{Potrero}_i + \varepsilon_{ij} \quad (3)$$

Donde: PPNA es la productividad primaria neta aérea mensual del potrero “i” en el mes “j” (kg MS ha⁻¹ Mes⁻¹). P es la precipitación mensual (mm Mes⁻¹). T corresponde a la temperatura promedio mensual (°C Mes⁻¹). Mes corresponde al mes del año. Potrero es cada uno de los potreros seleccionados. β_0 ... β_2 y α son los coeficientes determinados por el modelo. ln es el logaritmo natural con base e. ε corresponde al error aleatorio.

Los factores fijos del modelo están determinados por dos interacciones: la primera interacción corresponde a las precipitaciones para cada mes y la segunda interacción entre el mes y la temperatura. La parte aleatoria del modelo corresponden a los potreros y al error aleatorio. El factor temperatura y el factor precipitación resultaron significativos por sí solos, pero no fueron incluidos dentro del modelo debido a que resultaron significativas las interacciones entre factores y potreros. Debido a que la interacción entre las variables resulta una matriz de doce valores para precipitaciones y doce para temperaturas más el intercepto, el modelo está representado en la tabla 1:

Variable	Mes	Valor	Error estándar	t-valor	p-valor
β_0		5.795	0.04	129.87	0.000
Ln(P)	Ene	0.246	0.01	17.66	0.000
	Feb	0.137	0.02	8.69	0.000
	Mar	0.260	0.01	21.62	0.000
	Abr	0.132	0.01	11.92	0.000
	May	0.045	0.01	3.37	0.001
	Jun	-0.001	0.01	-0.10	0.924
	Jul	-0.008	0.01	-1.18	0.240
	Ago	-0.031	0.01	-2.45	0.014
	Sep	0.083	0.02	5.41	0.000
	Oct	0.002	0.02	0.09	0.928
	Nov	0.103	0.01	9.15	0.000
	Dic	0.189	0.01	17.63	0.000
T	Ene	-0.012	0.00	-4.12	0.000
	Feb	0.005	0.00	1.50	0.133
	Mar	-0.015	0.00	-5.43	0.000
	Abr	0.000	0.00	0.13	0.895
	May	0.016	0.00	4.03	0.000

	Jun	0.016	0.00	5.27	0.000
	Jul	0.022	0.00	8.66	0.000
	Ago	0.031	0.00	8.84	0.000
	Sep	0.010	0.00	2.39	0.017
	Oct	0.039	0.00	8.88	0.000
	Nov	0.017	0.00	6.23	0.000
	Dic	0.000	0.00	0.00	0.998

Tabla 1. Coeficientes del ajuste del modelo para estimación de la PPNA para campos naturales en Corrientes. Los meses que no resultaron significativos (p -valor $< 0,05$) se indican en rojo. Además de los coeficientes del modelo, la tabla contiene el error estándar de estimación y el valor del estadístico t .

Los valores de PPNA estimados van desde los 365,4 a 1135 kg MS ha⁻¹ mes⁻¹ con un desvío estándar de $\pm 165,1$ kg MS ha⁻¹ mes⁻¹. Y un promedio de 622,4 kg MS ha⁻¹ mes⁻¹.

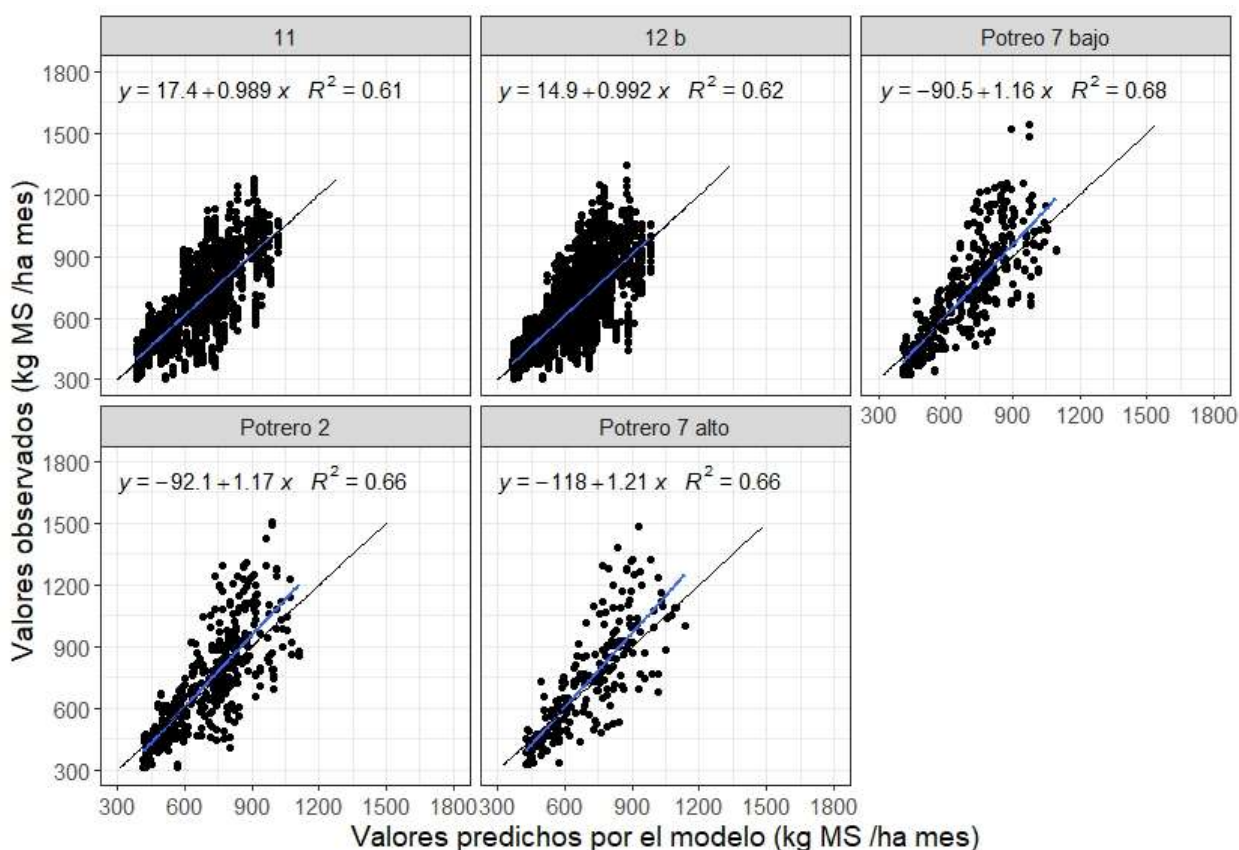


Figura 3 Relación lineal entre los valores observados de PPNA y los valores predichos de PPNA mediante el modelo ajustado por pixel MODIS para cada potrero. Cada punto representa la relación entre los valores observados de PPNA mediante teledetección y los valores predichos por el modelo ajustado. En el eje x se describen la PPNA en kg de materia seca por hectárea mensual predicho. En eje y se describen los valores de PPNA observados. La línea azul es la regresión lineal que representa la relación entre predichos y observados, con su ecuación y R^2 respectivamente. La línea negra muestra la relación 1:1 entre los ejes.

Cada panel de la figura muestra la relación entre los valores predichos de PPNA por el modelo y los valores observados por PIXEL para cada potrero. Cada potrero presenta valores de ajustes en términos de R^2 que va desde 0,61 a 0,68. Aumenta para los

potreros que poseen mayor número de píxeles del sensor MODIS, como son el potrero “7 alto”, “7 bajo” y “2”. Pero se observa que el sesgo, graficado por la línea azul, aumenta para valores de mayor PPNA. En cuanto a los potreros “11” y “12b” el ajuste disminuye (R^2 0,61 y 0,62 respectivamente) pero el sesgo disminuye. El sesgo representa una diferencia sistemática entre lo observado y lo que ajusta el modelo, puede relacionarse a un error sistemático, tanto en la medición de las variables, como en el ajuste del modelo.

Con el fin de evaluar el comportamiento del modelo se realizó la figura 4 que muestra la relación lineal entre los valores predichos y los valores observados para todo el conjunto de observación y sus respectivos valores predichos o ajustados por el modelo de PPNA para pastizales de Corrientes.




Figura 4 Relación lineal entre los valores predichos y observados de PPNA para todo el conjunto de datos. Los puntos representan los valores de PPNA en $\text{kg MS ha}^{-1} \text{mes}^{-1}$ en función del valor ajustado mediante el modelo de PPNA. En el eje x se muestran los valores predichos de PPNA. En el eje y los valores observados de PPNA mediante sensores remotos. La línea azul representa la relación lineal entre ambas variables con su respectiva ecuación y valor de R^2 . la línea negra muestra la relación 1:1 entre los valores de los ejes.

En la fig. 4 muestra que el modelo puede explicar hasta un 64% la variabilidad de la PPNA mediante variables ambientales. Con un sesgo mínimo representado por el ajuste de la regresión lineal, incluyendo los efectos aleatorios de los potreros. También se

observa que para valores altos de PPNA ($PPNA > 1100 \text{ kg MS ha}^{-1} \text{ mes}^{-1}$) el modelo predice por debajo de lo estimado.

4 DISCUSIÓN

Los valores obtenidos de PPNA ($\text{kg MS ha}^{-1} \text{ Mes}^{-1}$) observados en este trabajo son similares a valores obtenidos mediante cortes en la zona de estudio. Bedersky et al (2017) determinó valores de PPNA que van desde los $308 \text{ kg MS ha}^{-1} \text{ Mes}^{-1}$ hasta valores de $1400 \text{ kg MS ha}^{-1} \text{ Mes}^{-1}$ similares al rango observado mediante sensores remotos en el presente estudio (288 a $1539 \text{ kg MS ha}^{-1} \text{ Mes}^{-1}$).

Las variables temperaturas medias mensuales y precipitaciones medias mensuales mostraron relaciones estadísticas con la PPNA (Patton et al., 2007), similares a lo encontrado por Usandivaras (2006) en diferentes comunidades de pastizales en la región de Mercedes provincia de Corrientes. A pesar que para las precipitaciones en los meses de junio, julio y octubre, y para temperatura de febrero, abril y diciembre, no mostraron diferencias significativas, fueron incluidas en modelo para poder estimar la PPNA. Estas faltas de significancia estadística podrían salvarse utilizando los promedios para dichos meses, pero se decidió incluirlas dentro de los estimadores del modelo estadístico. La variable edáfica no presentó significancia estadística, a pesar que se observaron relaciones entre la PPNA y ciertos taxones específicos.

El modelo propuesto permite estimar la PPNA para pastizales naturales de la zona de Mercedes Corrientes, y explicar el 63% de la variabilidad mediante las precipitaciones y temperaturas medias mensuales (Tabla 1). A pensar que existen modelos que permiten ajustar la PPNA con mayor ajuste, como los citados Smoliak (1959) con ajustes de 65%, o Willes et al. (2011) entre 74 y 80%. El modelo propuesto se diferencia debido a que permite predecir la PPNA para un mes dado a partir de la precipitaciones y temperaturas obtenidas de estación meteorológicas. En cambio, estos autores presentan modelos que permiten determinar PPNA en función a variables climáticas por separado, además de no tener en cuenta la temporalidad (en este caso el mes).

El modelo ajustado presenta un buen ajuste para valores bajos como para valores medios de PPNA, pero se observa que para valores altos de PPNA presenta un sesgo sistemático, graficado mediante la diagonal del gráfico de observados vs predichos

(Figura 4). El ajuste mediante modelos lineales mixtos permitió analizar a los potreros como efecto aleatorio, haciendo que sea posible ajustar un modelo global que puede ser utilizado para el conjunto de potreros con pastizales naturales de la región de estudio. Este trabajo presenta un antecedente que mediante este tipo de ajustes estadísticos se pueden lograr modelos que permite aumentar el rango de utilización del modelo.

Los resultados encontrados en este estudio muestran que es posible determinar la PPNA a partir de variables meteorológicas para el manejo ganadero de pastizales de la región de Mercedes Corrientes, considerado un polo productivo para la provincia. Finalmente, si se aumentan el número de predios productivos, aumentando la cantidad de potreros relevados, con manejo de pastizales naturales, y re ajustando la metodología propuesta, se podrían realizar predicciones para todo el conjunto de potreros de la región, aumentando la extrapolación del modelo.

5 CONCLUSIONES

Fue posible determinar mediante el modelo de Monteith la PPNA de pastizales del sureste de Corrientes a partir de información obtenida de índices y variables derivadas de sensores remotos. Mediante el ajuste con modelos lineales mixtos se logró predecir hasta un 63% la variación de la PPNA de pastizales de la región. Se ajustaron como factores fijos las interacciones entre la temperatura y la precipitación del mes actual. Y en los efectos aleatorios se analizaron los potreros, permitiendo que modelo pueda ser usado para todo el conjunto de potreros de la estación experimental del INTA Mercedes. No se contemplaron como factores la precipitación o la temperatura por sí solas debido a que la interacción con el mes explicó de mejor manera la variabilidad de la PPNA.

6 REFERENCIAS BIBLIOGRÁFICAS

Adler, R. F., Huffman, G. J., Chang, A., Ferraro, R., Xie, P.-P., Janowiak, J., Rudolf, B., Schneider, U., Curtis, S., Bolvin, D., Gruber, A., Susskind, J., Arkin, P., y Nelkin, E. (2003). The Version-2 Global Precipitation Climatology Project (GPCP) Monthly Precipitation Analysis (1979–Present). *Journal of Hydrometeorology*, 4, 21.

Baldassini, P., Volante, J. N., Califano, L. M., y Paruelo, J. M. (2012). Caracterización regional de la estructura y de la productividad de la vegetación de la Puna mediante el uso de imágenes MODIS. *Ecología Austral* 22(1), 22-32.

Bates, D., Kliegl, R., Vasishth, S., y Baayen, H. (2018). Parsimonious Mixed Models. arXiv:1506.04967 [stat]. <http://arxiv.org/abs/1506.04967>

Bedersky, D., Pizzio, R., Maidana, C., Zapata, P., & Durante, M. (2017). Producción y curva de pastizales del Este de Corrientes. *INTA Ediciones* 542, 1–5.

Bork, E. W., y Werner, S. J. (1999). Viewpoint: Implications of Spatial Variability for Estimating Forage Use. *Journal of Range Management*, 52(2), 151. <https://doi.org/10.2307/4003509>

INTA. (2018). Asistencia técnica para el sector de la producción de la provincia de Corrientes. Cartografía de suelos y evaluación de tierras del departamento Mercedes, Corrientes. Informe final. Instituto Nacional de Tecnología Agropecuaria CR Corrientes EEA Corrientes-Recursos Naturales. 1-329

Graux, A.-I., Gaurut, M., Agabriel, J., Baumont, R., Delagarde, R., Delaby, L., y Soussana, J.-F. (2011). Development of the Pasture Simulation Model for assessing livestock production under climate change. *Agriculture, Ecosystems & Environment*, 144(1), 69–91. <https://doi.org/10.1016/j.agee.2011.07.001>

Grigera, G., Oesterheld, M., y Pacín, F. (2007). Monitoring forage production for farmers' decision making. *Agricultural Systems*, 94(3), 637–648. <https://doi.org/10.1016/j.agsy.2007.01.001>

Lauenroth, W. K., y Sala, O. E. (1992). Long-Term Forage Production of North American Shortgrass Steppe. *Ecological Applications*, 2(4), 397–403. <https://doi.org/10.2307/1941874>

- Li, F., Snow, V., y Holzworth, D. (2011). Modelling the seasonal and geographical pattern of pasture production in New Zealand. *New Zealand Journal of Agricultural Research*, 54(4), 331–352. <https://doi.org/10.1080/00288233.2011.613403>
- Martín, B., Galleano, V., Spiller, L. C., Vilche, M. S. y Montico, S. (2011). Evaluación de la productividad primaria de un pastizal templado en Santa Fe, Argentina. *Sitio argentino de Producción Animal*. 60 (232): 965-975.
- Oesterheld, M., Oyarzabal, M., y Paruelo, J. (2014). Aplicación de la teledetección y los sistemas de información geográfica al estudio y seguimiento de los sistemas ganaderos. En *Percepción remota y sistemas de información geográfica. Sus aplicaciones en Agronomía y Ciencias Ambientales* (pp. 283–301). Hemisferio Sur.
- Oyarzabal, M., Clavijo, J., Oakley, L., Biganzoli, F., Tognetti, P., Barberis, I., Maturo, H. M., Aragón, R., Campanello, P. I., Prado, D., Oesterheld, M., y León, R. J. C. (2018). Unidades de vegetación de la Argentina. *Ecología Austral*, 28(1), 040–063. <https://doi.org/10.25260/EA.18.28.1.0.399>
- Paruelo, J., Epstein, H. E., Lauenroth, W. K., y Burke, I. C. (1997). ANPP estimates from NDVI for the central grasslands' region of the United States. *Ecology*, 78(3), 953–958. [https://doi.org/10.1890/0012-9658\(1997\)078](https://doi.org/10.1890/0012-9658(1997)078)
- Paruelo, J., Oesterheld, M., y Grigera, G. (2010). Evaluación de recursos forrajeros mediante sensores remotos. Universidad de Buenos Aires, Seminario de discusión (Variabilidad climática y el funcionamiento de los ecosistemas), 7.
- Patton, B. D., Dong, X., Nyren, P. E., y Nyren, A. (2007). Effects of Grazing Intensity, Precipitation, and Temperature on Forage Production. *Rangeland Ecology & Management*, 60(6), 656–665. <https://doi.org/10.2111/07-008R2.1>
- Pizzio, R. (2014). Carga animal, escala predial y su implicancia en la sustentabilidad de sistemas. *INTA Ediciones*, 509, 1–6.
- Pizzio, R., Herrero-Jáuregui, C., Pizzio, M., y Oesterheld, M. (2016). Impact of stocking rate on species diversity and composition of a subtropical grassland in Argentina. *Applied Vegetation Science*, 19(3), 454–461. <https://doi.org/10.1111/avsc.12229>

R Core Team (2019). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0. <http://www.R-project.org>

Romero-Sanchez, M. E., y Ponce-Hernandez, R. (2017). Assessing and Monitoring Forest Degradation in a Deciduous Tropical Forest in Mexico via Remote Sensing Indicators. *Forest*. 8(302) 1-19. <http://dx.doi.org/10.3390/f8090302>

Sala, O. E., y Austin, A. T. (2000). Methods of Estimating Aboveground Net Primary Productivity. En O. E. Sala, R. B. Jackson, H. A. Mooney, y R. W. Howarth (Eds.), *Methods in Ecosystem Science* (31–43). Springer New York. https://doi.org/10.1007/978-1-4612-1224-9_3

Smoliak, S. (1956). Influence of climatic conditions of forage production.pdf. *Journal of Range Management*, 9(2), 89–91. <https://doi.org/10.2307/3894557>

Stackhouse, P. W., Perez, R., Sengupta, M., Knapp, K., Mikovitz, J. C., Schlemmer, J., Scarino, B., Zhang, T., y Cox, S. J. (2016). An Assessment of New Satellite Data Products for the Development of a Long-term Global Solar Resource At 10-100 km. *Proceedings of the Solar 2016 Conference*, 1–6. <https://doi.org/10.18086/solar.2016.01.24>

Usandivaras, L. M. A. (2006). Controles climáticos de la productividad primaria de pastizales de la provincia de corrientes. Tesis de Grado-Universidad de Buenos Aires. 1-51

Wiles, L. J., Dunn, G., Printz, J., Patton, B., y Nyren, A. (2011). Spring Precipitation as a Predictor for Peak Standing Crop of Mixed-Grass Prairie. *Rangeland Ecology & Management*, 64(2), 215–222. <https://doi.org/10.2111/REM-D-09-00024.1>

Zuur, A., Ieno, E. N., Walker, N., Saveliev, A. A., y Smith, G. M. (2009). *Mixed Effects Models and Extensions in Ecology with R*. Springer-Verlag. <https://doi.org/10.1007/978-0-387-87458-6>