

UNIVERSIDAD NACIONAL DEL CALLAO

Facultad de Ingeniería Ambiental y de Recursos Naturales



**USO DE DATOS DE TEMPERATURA SUPERFICIAL DE
AGUA DE MAR COMO APOYO EN LAS TOMAS DE
DECISIONES AGRICOLAS**

Tesis para Optar el Título de:

INGENIERO AMBIENTAL Y DE RECURSOS NATURALES

JANETH PAOLA PIZARRO RAMOS

CALLAO – Perú

2006

Dedicatoria

*A Mis Padres
Pedro y Maura
Por su gran apoyo y enorme comprensión*

*A Mis hermanos
Pedro, Elizabeth y Zoraida*

*Y a mis mejores amigos
por su sincera amistad*

AGRADECIMIENTO

Al Centro Internacional de la Papa (CIP) que me brindó la oportunidad de desarrollar el presente trabajo de investigación.

A la Ing. Ena Jaimes Espinoza, asesora del presente trabajo de investigación, por su amistad y confianza.

Al PhD. Guillermo Baigorria Paz por su asesoría permanente y facilitar la realización de este trabajo, por sus grandes consejos y sabiduría.

Al PhD. Consuelo Romero por sus consejos, amistad y confianza.

Y a todos aquellos que permitieron mejorar este trabajo de investigación. A mis profesores Gracias.

- RESUMEN

Ante el crecimiento desmesurado de la población humana, la seguridad alimentaria constituye una de las mayores preocupaciones a nivel mundial. En zonas de subsistencia como los Andes Peruanos, la variabilidad climática estacional condiciona un factor de riesgo importante por su impacto en la producción agrícola. En el presente trabajo se analizó y evaluó el efecto de la Temperatura Superficial de Agua de Mar (TSM) como un indicador del pronóstico de la variabilidad climática estacional, donde la ayuda de herramientas de simulación traduce esta información en mapas de producción determinándose fechas óptimas de siembra.

La metodología desarrollada en el presente trabajo de investigación emplea un proceso conocido comúnmente como downscaling estadístico o desagregación estadística. Así, se realizó una desagregación espacial y temporal de datos de temperatura superficial de agua de mar (TSM) generando ecuaciones de pronóstico de la variabilidad climática estacional para el período comprendido entre septiembre del 2003 y marzo del 2004, en diferentes zonas agroecológicas (ZAC).

El área de estudio es en las cuencas La Encañada - Tambomayo. Dentro de la cuenca se identificaron tres zonas agroecológicas (valle, ladera y jalca), con una estación meteorológica situada en cada una de ellas, representando así cada estación una ZAC.

El modelo desarrollado está basado en ecuaciones de regresión múltiple. Las series de tiempo de precipitación y temperatura del aire de las Estaciones Meteorológicas, constituyen las variables dependientes. Las variables independientes corresponden a datos de temperatura superficial de agua de mar proporcionados por la Administración Oceánica y Atmosférica Nacional (NOAA) para la ubicación correspondiente a 60W-180W y 20N-25S. Para el análisis estadístico y gestión de los datos se utilizó el software Climlab 2000. Asimismo se realizó la calibración, validación y uso de los pronósticos de NOAA de 2003-2004 para las tres estaciones meteorológicas localizadas dentro de la cuenca. Donde se demostró que los modelos de regresión múltiple resultaron bastante apropiados para años normales y el análisis de residuales sugirió generar nuevas ecuaciones para años con presencia del Fenómeno de El Niño o de la Niña. Finalmente, debido a las correlaciones encontradas entre TSM y la

variabilidad climática estacional, y el uso de herramientas de simulación se generaron los mapas de fechas óptimas de siembra. El cultivo seleccionado para realizar la aplicación de la metodología es el cultivo de papa, ya que constituye uno de los principales cultivos y de mayor distribución dentro del área de estudio. Así se encontró que los Agricultores en los Andes no siembran en fechas óptimas afectando esto posiblemente sus ingresos económicos. Esto puede deberse a la falta de una herramienta confiable que permita la optimización de la producción adoptando solamente una política de minimización de riesgos. Mediante la generación de los mapas se busca dar soporte con suficiente anticipación a las personas que toman decisiones y así reducir el riesgo a la vulnerabilidad climática y garantizar una mejor calidad de vida en zonas de subsistencia.

SUMMARY

The population's excessive growth and the alimentary security are one of the biggest concerns in the world in areas of livelihood as The Peruvian Andes. The seasonal climate variability constitutes an important factor of risk by their impact in the agricultural production. In the present document has analyzed and evaluated the effect of the Surface Sea Temperature (SST) as an indicator of forecasting of the seasonal climate variability, where the help of simulation tools translate this information to production maps with optimal planting date.

The methodology developed is based in a spatial and temporal downscaling from the data of Sea Surface Temperature (SST). And look to find forecast equations from climate variability seasonal for the period of September 2003 to march 2004 for each agro-ecological zone (ACZ).

The study area is located in the La Encañada - Tambomayo watershed. It has sub-divided the watersheds in there agro-climatic zone (ACZ) denominated as highlands, hillside, and valley. In each of these ACZs a weather station is located. The model developed is based on multiple regressions's equations. Time series data of maximum and minimum temperature and rainfall from weather stations are dependent variable. The independent variable corresponds to SST data which were obtained from National Oceanic and Atmospheric Administration (NOAA) between 60°N to 180°W and 20°N to 25°S. For the statistical analysis and administration of the data used Climlab 2000 software. Likewise was developed first the calibration, after the validation and after that it has used the forecast data of 2003 - 2004 from NOAA for the three weather stations located in watersheds the La Encañada - Tambomayo. According to the multiple regression models, maximum and minimum temperatures, as well as rainfall, are expected to be close to normal conditions in the cropping season and the residual analysis suggested that the developed multiple regression models are quite appropriate for normal years and also suggested to generate other equations to each specific extreme meteorological event. So finally, according to the correlation index (R^2) found between SST and seasonal climate variability, and use of simulations tools have generated optimal planting – date maps. The potato's cultivation was selected to develop an application of the methodology. The potato is

one of the most important cultivation and major distribution in the study area. Thus was found that the farmers in the Andes not planting in optimal date affecting this possibly their economy. This can be due to the lack of a reliable tool that allows the optimization of the production adopting only a politic of minimization of risks. Through the generation of the maps to search to give support with enough anticipation to decision markers and so to reduce the risk to the climatic vulnerability and guarantee a better quality of life in areas of livelihood.

Título: Uso de datos de temperatura superficial de agua de mar como apoyo en las tomas de decisiones agrícolas

INDICE

- I. Introducción
- II. Revisión Bibliográfica
 - 2.1 Problemática de las Zonas Altoandinas
 - 2.2 Los pronósticos Climáticos y las Decisiones Agrícolas
 - 2.3 Modelo de Circulación General (MCG)
 - 3.3.1 Problemas de Impacto de la Resolución Espacial
 - 2.4 Downscaling o Desagregación Estadística
 - 2.5 Herramientas de Simulación
 - 2.5.1 Generalidades sobre Modelos Biofisicos
 - 2.5.2 Sistema de Apoyo para las Decisiones de Transferencia de Agrotecnología (DSSAT)
 - 3.5.2.1 SUBSTOR – Potato
 - 3.5.2.2 Weather Generator – WGEN
 - 2.5.3 Laboratorio de Modelamiento Biofisico y SIG (GABP-Lab)
- III. Metodología
 - 3.1 Área de Estudio
 - 3.2 Materiales
 - 3.2.1 Software Climlab 2000
 - 3.2.2 Colección de datos
 - 3.2.3 Recopilación de información sobre el manejo de cultivos
 - 3.2.4 Herramientas de simulación
 - 3.2.5 Mapas utilizados en la simulación de Gabp-Lab
 - 3.2.5.1 Mapas de clima
 - 3.2.5.2 Mapas de suelos
 - 3.2.5.3 Mapas de pendiente

3.3 Métodos

- 3.3.1 División de la base de datos de clima a nivel de estación meteorológica
- 3.3.2 Desagregación especial del MCG
 - 3.3.2.1 Estandarización de resoluciones de información observada y del pronóstico de TSM
 - 3.3.2.2 Análisis de los datos meteorológicos de la temperatura superficial de agua de mar (TSM)
 - 3.3.2.3 Matriz de correlación
 - 3.3.2.4 Análisis de regresión múltiple
 - 3.3.2.5 Calibración
 - 3.3.2.6 Validación
- 3.3.3 Aplicación
 - 3.3.3.1 Uso de TSM pronosticado
 - 3.3.3.2 Desagregación temporal de los pronósticos climáticos estacionales
- 3.3.4 Integración de la información de clima y las herramientas de simulación
 - 3.3.4.1 Mapas de fechas óptimas de siembra

IV. Resultado y Discusión

- 4.1 Calibración
- 4.2 Validación y comparación
- 4.3 Aplicación
- 4.4 Evaluación del pronóstico de producción

V. Conclusiones y Recomendaciones

- 5.1 Conclusiones
- 5.2 Recomendaciones

VI. Bibliografía

INTRODUCCIÓN

La variabilidad climática estacional condiciona un factor de riesgo importante, donde las heladas, granizo y déficit de precipitaciones amenazan la seguridad alimentaria principalmente en zonas altoandinas, donde se desarrolla una economía de subsistencia. Existe una fuerte preocupación por parte de la comunidad científica en tratar de predecir y prevenir algunos de estos eventos.

El conocimiento previo de la cantidad y distribución de las precipitaciones tiene, potencialmente, una importancia especial para la seguridad alimentaria y los programas de reducción de la pobreza (Blench, 1999). La capacidad de predecir es importante porque ayuda a evaluar como un evento afectaría la cantidad de campos que se sembrarían, el tipo de cultivos y variedades a emplear (Huanta, Markowitz y Jetté, 1994; Céspedes y Rodríguez, 1995; Hanson, 2002; Baigorria, 2005). El principal problema de los pronósticos climáticos que dificulta su utilización y aprovechamiento es la inadecuada escala espacial en la que es proporcionada y la falta de entrenamiento en la interpretación de la misma ya que muchas veces hablamos de diferentes escalas de impacto.

Bierkens,*et al* (2000) identifican tres tipos de escalas diferentes involucradas en una investigación aplicada: a) escala de observación, b) escala de modelo y c) escala de política. La escala de observación, es la escala en la cual una observación proporciona un valor promedio, por ejemplo: una medida de temperatura del ambiente, que representa la temperatura promedio para una determinada zona en un cierto tiempo. La escala de modelo, es la escala en la cual el modelo proporciona sus salidas: por ejemplo, un modelo de circulación global (MCG) proporciona temperatura promedios del mar en una resolución de 100x100x10 Km para períodos de treinta años. La escala de política, es la escala en la cual los proyectos de investigación son requeridos en orden de responder preguntas de los que toman decisiones. Esta también es la escala en la cual las decisiones son hechas y la política es implementada. Entonces se puede observar que mientras se va a través del ciclo de investigación la información debe ser transferida de una escala a otra, esto es lo que se denomina transferencia de escala y así es posible generar información útil

y aprovechable en la escala de interés permitiendo su aplicación en diferentes campos de las ciencias ambientales.

La predicción de la variabilidad climática en una escala global no es de mucha ayuda debido a su baja resolución (Valdivia et al, 2002). Ya que se toman las decisiones al nivel de parcela, y los agricultores andinos tienen el interés vital de sobrevivir a la variabilidad del clima.

Baigorria (2005) señala que las decisiones agrícolas involucran diferentes aspectos tales como impactos ambientales, inversiones, rotación de cultivos, respuestas de la planta, y las decisiones de manejo diario, pero estas decisiones son tomadas dentro del contexto de información disponible tales como recursos naturales, precios y clima. Además menciona que de acuerdo a investigaciones realizadas en los Andes Peruanos los agricultores buscan reducir el riesgo a la vulnerabilidad climática sembrando sus campos antes y durante los meses iniciales a la estación lluviosa evitando sembrar todos sus campos en fechas específicas o con el mismo cultivo asegurando solo así una producción mínima para su consumo y limitando la comercialización de sus productos y por ende un escaso o nulo ingreso adicional que le permita desarrollar una mejor calidad de vida.

El presente trabajo de investigación enfoca el uso y aplicación de los datos de clima como herramienta de soporte en las decisiones agrícolas a fin de disminuir el riesgo a la vulnerabilidad climática estacional a través del desarrollo de una metodología de aprovechamiento de los datos de temperatura superficial de agua de mar en las decisiones agrícolas, ya que es conocido que la Temperatura Superficial de Agua de Mar (TSM) ejerce influencia sobre el clima estacional, condición que será validado y evaluado mas adelante con el desarrollo de la metodología constituyéndose entonces la TSM en un parámetro importante de predicción y así contribuyendo en la generación de estrategias dando un uso potencial a los pronósticos de clima y asegurando la demanda alimentaria en zonas de subsistencia desarrollándose un caso para la Cuenca La Encañada – Tambomayo. *Siendo así la hipótesis planteada que la temperatura superficial de agua de mar incide en la variabilidad climática estacional y determina fechas óptimas de siembra para el cultivo de papa.* Dentro del área de estudio el cultivo de papa es uno de los cultivos principales y de mayor distribución por tal razón en el presente trabajo se decidió realizar la aplicación de la metodología a este cultivo.

El objetivo general del presente trabajo de investigación es Desarrollar una metodología de pronóstico climático estacional como herramienta de apoyo en las decisiones agrícolas. Entonces se planteó los siguientes objetivos específicos: a) establecer las correlaciones entre temperatura superficial de agua de mar y datos registrados de precipitación y temperatura del aire para la cuenca La Encañada – Tambomayo; b) realizar una aplicación de pronóstico para una campaña agrícola en la cuenca La Encañada – Tambomayo y c) analizar el uso de pronósticos climáticos estacionales en las decisiones agrícolas.

II. REVISIÓN BIBLIOGRÁFICA

2.1 PROBLEMÁTICA DE LAS ZONAS ALTOANDINAS

Los Andes representan uno de los lugares de mayor diversidad biológica y riesgos relacionados al relieve y el clima principalmente (Baigorria, 2005). La agricultura es la principal fuente de ingreso de la población rural, y las perturbaciones climáticas son el factor determinante para la producción agrícola en la región (Le Tacon, 1989). Esta situación exige que las sociedades desarrollen estrategias que permitan garantizar una mejor calidad de vida. La economía andina no busca maximizar las ganancias monetarias, sino asegurar la estabilidad de ciertos niveles mínimos de subsistencia a largo plazo. Busca un balance entre los esfuerzos invertidos (financieros, fuerzas de trabajo, materiales, etc) y la satisfacción de la unidad familiar (Boelens, 1998). Así, Sánchez (2004) señala que el alto nivel de pobreza en las zonas altoandinas constituye uno de los mayores problemas ambientales, el mismo que tiende a elevarse debido al deterioro de los recursos naturales que son el soporte de la principal actividad económica de la región.

Un estudio realizado en tres comunidades agro pastoriles en el altiplano de Bolivia señala que el 30% de niños menores de 5 años sufren de desnutrición (Murillo *et al*, 1995), y que el estado nutricional está relacionado directamente a la capacidad de los padres en producir sus alimentos y enfrentar los riesgos de sequías y heladas, constituyéndose en clave elemental para mejorar la calidad de vida de las familias rurales.

El Consorcio para el Desarrollo Sostenible de la Ecorregión Andina (CONDESAN, 2003) citado por Sánchez (2004), señala que más del 60% de los habitantes rurales de los Andes todavía viven en la pobreza. Menos de la mitad tienen acceso a servicios de salud, agua potable y saneamiento básico. Uno de cada nueve niños no llega a cumplir su primer año de vida. Si bien los problemas específicos varían de sitio en sitio, el crecimiento de la población, la erosión de los suelos y pérdida de nutrientes, las sequías, heladas e inundaciones, la deforestación, la salinización de los suelos, la violencia política y la marginación del mercado son los principales obstáculos para el desarrollo social y económico de la región.

Bernet (1999) citado por Valdivia (2002), señala que la situación económica de los agricultores en la cuenca La Encañada - Tambomayo esta fuertemente determinada por las diferencias en el clima, topografía y acceso a la irrigación. Las pendientes varían de 5% a más del 100% (100% = 45 grados) y de acuerdo al Ministerio de Agricultura la máxima pendiente recomendada para sembrar cultivos es del 21% (aproximadamente 12 grados). Así Romero y Stroosnijder (2001) encontraron que el 35% del área presenta gradientes de pendiente mayores que el 15% y que gradientes de pendientes mayores al 65% pueden ocurrir. El 70% de la agricultura es de subsistencia, mientras que sólo el 3% de los terrenos cultivados están bajo riego. En cuanto a sus ingresos son muy bajos, ya que el tamaño de las parcelas en promedio es menos de 3 hectáreas dificultando las posibilidades de ahorro e inversión de dinero. Baigorria, *et al.*, (2002), señalan que los pobladores de la cuenca La Encañada - Tambomayo tienen un ingreso promedio diario menor a US\$1. La tasa de mortalidad infantil (muertos/1000) es de 70, siendo las enfermedades comunes bronquitis, desnutrición, tuberculosis y diarrea. El índice de desnutrición de los niños es del 67 al 85%. Sólo el 45% de los pobladores tienen acceso a servicios de agua potable. Estas cifras han motivado que durante las últimas décadas se hayan intensificado los esfuerzos por elevar el nivel de vida de la población andina. Cajamarca, no estuvo ajeno a ese objetivo tal es así que por más de 50 años se han llevado a cabo diferentes proyectos de desarrollo con la intervención de diversas instituciones. Según investigaciones efectuadas por el proyecto PIDAE (Proyecto Integral de Desarrollo Agropecuario de la Encañada), los proyectos han orientado su acción al incremento de la producción, la conservación y el uso apropiado de los recursos de los ecosistemas altoandinos.

2.2 LOS PRONÓSTICOS CLIMÁTICOS Y LAS DECISIONES AGRICOLAS

Hansen (2002) señala que las poblaciones rurales son a menudo vulnerables a la variabilidad climática por el impacto en la producción agrícola, y que la vulnerabilidad no es solamente una consecuencia de la variabilidad del clima de un año a otro, sino también de su incertidumbre. Las incertidumbres del clima requieren que aquellos que toman decisiones preparen posibles alternativas que permitan reducir los impactos negativos y conduzcan a generar estrategias de manejo y así minimizar los riesgos. Las variaciones del clima están fuertemente influenciadas por la interacción océano – tierra – atmósfera. Aunque la atmósfera

fluctúa muy rápidamente, las características de superficie tales como la temperatura superficial de agua de mar (TSM), cobertura de nieve y humedad del suelo cambian lentamente y son capaces de influenciar el clima en largos períodos de tiempo. Así White *et al* (1997) encontraron que los patrones globales de TSM se correlacionan adecuadamente (i.e., >0.9) con patrones globales de precipitación sobre continentes adyacentes en escalas de tiempo interanual. En particular, el sistema climático global interactúa fuertemente con patrones espaciales de temperatura superficial del Pacífico tropical, tal como lo asociado con la Oscilación Sur de El Niño o ENSO que esta referido a cambios de TSM en el Pacifico Ecuatorial. Cuando la TSM esta más caliente de lo normal se presenta El Niño y cuando esta mas fría de lo normal, La Niña (Hansen 2002).

La agricultura es el principal ingreso económico para los pobladores de los Andes y las perturbaciones climáticas son el factor determinante para el desarrollo de la agricultura en la región (Le Tacon, 1989). Estas regiones se caracterizan por su alta variación diurna de temperatura, riesgos de heladas, precipitación irregular, riesgos de sequía durante la estación de crecimiento (Francois *et al* , n.d.). Sin embargo, la aplicación efectiva de los pronósticos climáticos a la agricultura de una región no sólo depende de la disponibilidad de los mismos y del conocimiento de la vulnerabilidad del sector, sino que además: 1) deben existir opciones objetivas para traducir el conocimiento del clima futuro en prácticas que mejoren las decisiones actuales y 2) es necesario conocer la posibilidad, habilidad y predisposición de quienes toman decisiones para modificar sus planes en base a la información disponible.

La existencia de opciones objetivas para adaptar las producciones al tipo de año se relaciona con el uso de herramientas que permitan evaluar alternativas. Actualmente se dispone de modelos de cultivo que predicen los rendimientos bajo diferentes condiciones del ambiente (suelo y clima), y permiten ofrecer distintas alternativas de manejo tendientes a optimizar los rendimientos e ingresos económicos según las características ambientales pronosticadas.

La adopción de las alternativas de manejo óptimo de acuerdo al clima pronosticado dependerá de la posibilidad, habilidad y predisposición de quien toma la decisión para cambiar sus planes. Por ejemplo, si el pronóstico climático anunciara la ocurrencia de una fase Niño o Niña con suficiente anticipación, existiría la posibilidad de adoptar cualquier opción,

incluyendo la de cambiar de cultivo. Sin embargo si el pronóstico se conociera tarde ciertas opciones como cambiar de cultivo, utilizar variedades o híbridos de ciclo mas largo o adelantar la fecha de siembra podrían resultar imposibles de considerar, es por esto que la capacidad de predecir es importante porque afectaría la cantidad de campos que se sembrarían, el tipo de cultivo y variedades (Huanca, Markowitz and Jetté, 1994; Céspedes and Rodríguez, 1995).

Blench (1999) señala que en las estrategias de preparación para los desastres se ha comenzado a tomar en cuenta estos pronósticos y existe un gran interés en asignarles un valor económico. Así los organismos multilaterales, como el Banco Mundial, insisten en que los pronósticos deben estar disponibles para los agricultores de pequeña escala, a fin de beneficiar la seguridad alimentaria.

Por otro lado, los agricultores, en la actualidad, utilizan su conocimiento tradicional, a través de señales, tales como pájaros e insectos para pronosticar el clima (Hatch, 1987) u otras tales como el viento, las nubes, la luna y el sol (Baigorria, 2005) y así incorporan sus pronósticos locales para asistirse en las decisiones operacionales con respecto al manejo del agua, nutrientes y protección del cultivo. Sin embargo Sánchez (2005), señala que a pesar de estos conocimientos tradicionales, los agricultores en los Andes no cuentan con una herramienta confiable para el pronóstico, que les permita la optimización de la producción, adoptando solamente una política de minimización de riegos.

2.3 MODELO DE CIRCULACIÓN GENERAL (MCG)

Trenberth (1992) señala que el tratar de determinar el comportamiento futuro del sistema climático a partir del conocimiento de los comportamientos del pasado y presente, se basa en dos métodos. Uno es el uso de métodos estadísticos, tales como ecuaciones de regresión con observaciones del presente y pasado para obtener la más probable extrapolación. El otro se basa en la creación de ecuaciones que representen los procesos físicos, químicos y biológicos que gobiernan el sistema climático para la escala de interés.

Desde que las anomalías de las TSM de los trópicos son conocidas como los controladores fundamentales de las anomalías atmosféricas climáticas, los pronósticos de anomalías de TSM es la primera tarea del pronóstico del clima.

Gerald (1992) señala, que el MCG océano incluye todos los elementos del balance de energía superficial y del almacenamiento de calor, más el realismo potencial de la corriente del océano, mezclando procesos de afloramientos de agua que contribuyen a calcular la distribución del hielo de mar y TSM. Los MCG son complejos, pero están limitados en el nivel de detalle espacial que representan, debido a que las computadoras no son lo suficientemente rápidas para realizar cálculos de variables climáticas de toda la tierra, la atmósfera y TSM en un tiempo razonable. Por esto los cálculos son ejecutados en puntos ampliamente espaciados en una grilla tridimensional para una determinada superficie. El espaciamiento entre los puntos de la grilla es la “resolución espacial”.

La información de TSM es proporcionada a través de mapas digitales a nivel global (para toda la esfera terrestre). Los datos de TSM se encuentran distribuidos en celdas o píxeles a intervalos igualmente espaciados (esto es lo que se denomina resolución espacial), donde a través de procesos de interpolación y ayuda de herramientas de Sistemas de Información Geográfica (SIG) se visualiza esta información en mapas.

2.3.1 Problemas de Impacto de la Resolución Espacial

La NOAA proporciona información global de TSM en una resolución espacial de 2° latitud X 1.5° de longitud (1° ~ 110 km). Esta resolución resulta muy baja para evaluar impactos y tomar decisiones a nivel local o puntual como las decisiones agrícolas, desde que por cada área de 36 300 km² (2 x (110) x 1.5 x (110)) se cuenta con un dato de TSM. Entonces, informaciones de pronósticos del clima en una resolución espacial grande, no tienen aplicación en el nivel que la decisiones requieren ser tomadas.

Hansen (2002), señala que uno de los requisitos para utilizar los pronósticos climáticos en beneficio de las decisiones agrícolas, es predecir componentes relevantes de la variabilidad climática para períodos decisivos, en una escala o resolución espacial apropiada, con suficiente anticipación de tiempo y con la exactitud que permita tomar

decisiones pertinentes. Los adelantos en la comprensión de las interacciones entre la atmósfera, los océanos y la superficie terrestre están revolucionando las ciencias de la tierra. Actualmente los esfuerzos se enfocan principalmente en obtener modelos dinámicos de la atmósfera y evaluar su interacción con el océano y superficie terrestre. Cabe resaltar que, por ahora, el resultado de las predicciones obtenidas a partir de los pronósticos dinámicos no son necesariamente mejores que los obtenidos con el empleo de herramientas estadísticas (Barnston *et al.*, 1994; Anderson *et al.*, 1999; Cane, 2001).

Para adoptar medidas que mitiguen el riesgo de los efectos del clima es necesario estudiar los posibles futuros comportamientos de la variabilidad climática. Entonces, es importante desarrollar herramientas de previsión que representen las preocupaciones potenciales de la población de zonas rurales, así como integrar esta información en la toma de decisiones agrícolas (Gilles *et al.*, 2001). Además, la información de la variabilidad estacional sólo será útil si alternativas tecnológicas o políticas son capaces reducir el riesgo (Valdivia, 2002).

2.4 DOWNSCALING ESTADÍSTICO O DESAGREGACION ESTADISTICA

El método de Reducción de Escala permite establecer relaciones entre las variables simuladas por el Modelo Atmosférico de Circulación General (MCGA) y las variables a nivel local. (Wilby & Wigley, 2000).

Sailor (2000), señala que los procesos de downscaling o desagregación asumen que los MCG son buenos estimadores de variables en una escala grande y que el acercamiento implica relacionar parámetros de la escala grande (e.g., vientos superiores, altura geopotencial, y presión a del nivel del mar) con observaciones históricas del parámetro superficial del interés (temperatura, precipitación, velocidad del viento, etc.) y que la función de transferencia requerida se puede desarrollar utilizando una amplia gama de herramientas tales como: Métodos de Regresión, Patrones de tiempo, Generadores estocásticos de tiempo, así como Modelos climáticos regionales (Wilby & Wigley, 2000); y una vez desarrollada la función de transferencia se asume que va a seguir siendo invariante bajo condiciones de cambio del clima y se aplica a los parámetros de una escala grande, es decir a la información de los MCG. El resultado es una predicción del parámetro superficial de interés bajo condiciones de cambio climático.

Climate Forecasting Group (2001), señala que en la década de los noventa, los métodos de Reducción de Escala, se han empleado para estimar variables climáticas a nivel local en los centros de pronósticos y en estudios climáticos. Para el primer propósito a partir de las simulaciones de un modelo de circulación general atmosférico y utilizando la metodología de análogos se realizan estimaciones para estimar períodos con anomalías de temperatura a nivel local.

Solman y Núñez (1999), realizando proyecciones climáticas para la región de Argentina, empleando el método de reducción de escala por medio de modelos de regresión y las simulaciones del modelo HADAM y MPI proyectaron cambios para la temperatura del aire en los meses de verano mayores a 2 °C en la región central. Durante el invierno el aumento proyectado resultó más bajo.

En otros enfoques particulares se han aplicado métodos estadísticos multivariados como funciones ortogonales empíricas, correlación canónica definiendo los conceptos de patrones espaciales y temporales para analizar campos meteorológicos. (Storch y Zwiers, 1999).

Storch (1999) señala que como es preciso realizar estimaciones de futuros cambios en una escala regional y local a partir de Modelos Atmosféricos de Circulación General (MCGA), las técnicas de reducción de escala dinámicas y estadísticas permiten representar los cambios de elementos como temperatura media en superficie y la precipitación en una escala regional y local.

Trueba, Gutiérrez, Cofiño y Rodríguez (2000) señalaron que metodologías basadas en redes neuronales y en análogos han sido empleadas como apoyo en la reducción de escala para simular condiciones meteorológicas locales, haciendo uso de información simulada por un modelo de circulación general atmosférico, así como observaciones de datos generados a partir de mediciones en estaciones meteorológicas. También se han empleado métodos de reducción de escala para estimar variables climáticas a nivel local y con propósitos de pronósticos del tiempo para estimar anomalías de temperatura diaria y precipitación (Kidson & Thompson 1997). En estudios climáticos el método de Reducción de Escala ha estado enfocado principalmente, a reducir la escala espacial de las proyecciones climáticas de temperatura del aire y precipitación útiles para estudios de impacto climático a nivel local. (IPPC, 1997).

2.5 HERRAMIENTAS DE SIMULACIÓN

Bowen et al. (2000), señala que los modelos de simulación son un importante medio para aumentar la eficiencia de la investigación ya que estos pueden auxiliar a los investigadores en la asimilación del conocimiento adquirido mediante la experimentación y proporcionan un marco de referencia para aportaciones de carácter multidisciplinario; asimismo, promueven el método de análisis de sistemas para la solución de problemas y facilitan una organización sistemática del conocimiento existente sobre cultivos y recursos naturales.

2.5.1 Generalidades sobre los modelos biofísicos

Jones (1993) citado por Sánchez (2005), menciona que el uso de modelos de simulación que describen procesos biofísicos permite el análisis de los factores limitantes presentes en la producción de cultivos. Por su parte Hunt y Boote (1998), mencionan que la aplicación de modelos de simulación en resolver problemas del mundo real dependería no solo de la disponibilidad de los modelos y de los software de aplicación, sino también, de la disponibilidad de la información que haría posible ejecutar los modelos para escenarios particulares y con la precisión requerida para una región en particular. La precisión de los resultados de los modelos, está condicionada por las limitaciones de los mismos, por la calidad de la información climática y de suelos, así como por su variabilidad espacial y temporal. Una cuestión importante de los modelos de simulación es que mientras los modelos de cultivo están referidos a puntos específicos, la agricultura ocurre en un espacio y tiempo determinado (Beinroth et al., 1998).

2.5.2 Sistema de Apoyo para las Decisiones de Transferencia de Agrotecnología (DSSAT)

Sánchez (2005), señala que son modelos de cultivos basados en procesos biofísicos, combinados en un paquete, que fueron desarrollados bajo los auspicios de la Red Internacional de Sitios pilotos para la Transferencia de Agrotecnología (IBSNAT, siglas en inglés). Estos modelos utilizan un juego estándar de datos de acceso (inputs) y producen un juego estándar de datos de salida (outputs), simulando el crecimiento y rendimiento de la planta y otros resultados a medida que se incrementa el nivel de

complejidad (Figura 1). Al aumentar el nivel de complejidad en la simulación del crecimiento de un cultivo, la demanda de datos de acceso también aumenta. Los requerimientos de información son acumulativos, por lo tanto, los datos necesarios a un nivel también lo son al nivel superior. Para todos los niveles de complejidad, los modelos de simulación requieren, como mínimo, valores diarios de radiación solar, temperaturas máximas y mínimas del aire y precipitación pluvial. Estas cuatro variables determinan los procesos que son descritos dentro de los modelos (Bowen *et al.* 2000).

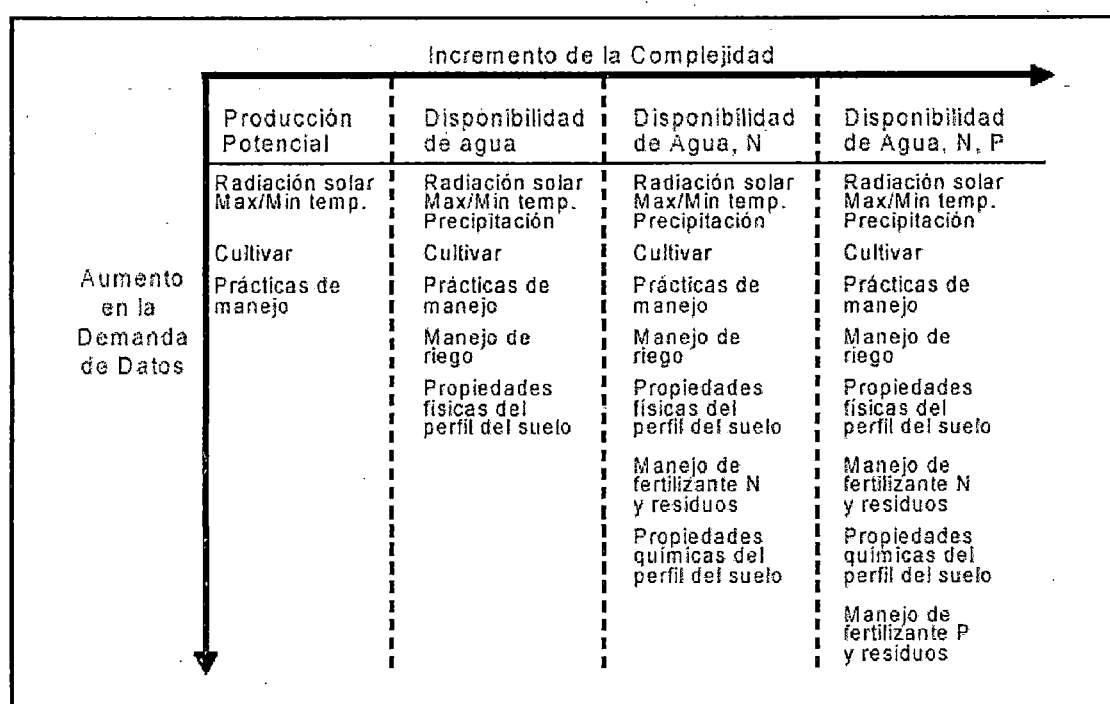


Figura 1. El incremento de los datos necesarios para ejecutar los modelos de simulación de cultivos de DSSAT cuando se incrementa la complejidad de las simulaciones (Bowen *et al.* 2000).

2.5.2.1 Modelo de Cultivo de papa (SUBSTOR – Potato)

Es un modelo de cultivo disponible en DSSAT, que permite simular el crecimiento de un cultivo de papa. Bowen, (1997) señala que SUBSTOR-Potato, es una herramienta útil para analizar efectos cuantitativos de factores controlados (por ejemplo: manejo del

cultivo) y no controlados (por ejemplo: clima) en el rendimiento del cultivo de papa, teniendo en cuenta propiedades específicas del suelo y componentes principales del balance del nitrógeno. El modelo es integral y simula procesos principales asociados con la demanda de nitrógeno por el cultivo y el suministro de éste por el suelo, asimismo, proporciona un acercamiento detallado para describir procesos en el suelo y planta. Todos los procesos listados en la Tabla 1 son simulados usando series diarias de tiempo.

Tabla 1. Procesos principales que son simulados y factores ambientales que afectan estos procesos en el submodelo SUBSTOR-Potato (DSSAT)

Procesos simulados	Principales factores que influyen en el proceso
<u>Demanda de nitrógeno por el cultivo</u>	Radiación Solar, temperatura Fotoperíodo, temperatura
Crecimiento	
Desarrollo	Temperatura del suelo, agua en el suelo y relación C:N
<u>Suministro de N al suelo</u>	Temperatura del suelo, agua en el suelo, pH del suelo, concentración de NH_4^+
Míneralización / Inmovilización	Temperatura del suelo, agua del suelo, pH del suelo, C del suelo
Nitrificación	
Denitrificación	Drenaje
Lixiviación de NO_3^-	Temperatura del suelo, agua en el suelo, pH del suelo,
Hidrólisis de Urea	C del suelo
Captación	Agua en el suelo, N inorgánico, demanda del cultivo, densidad de longitud de raíz.

Fuente: Boyer, 1997
2.5.2.2 Weather Generator – WGEN

El WGEN (Richardson y Wright, 1984) estima aleatoriamente valores diarios de precipitación temperatura máxima, temperatura mínima y radiación solar para un período de “n” años utilizando parámetros predeterminados de una locación. Este

modelo involucra procesos físicos que dependen de la temperatura, precipitación y radiación solar del día, conservando así dependencia en el tiempo.

Richardson y Wright (1984) señalan que los datos diarios son necesarios en muchas aplicaciones, como para ayudar en el diseño de estructuras hidráulicas, evaluar efectos de cambio en la hidrología de una cuenca, áreas de escorrentía, calidad de agua o erosión, entre otros.

2.5.3 Laboratorio de Modelamiento Biofísico y SIG (GABP-Lab)

GABP-Lab (Baigorria *et al.*, 2001), es una interfase que integra el modelo biofísico de cultivo (DSSAT), y el modelo de erosión de suelos basados en procesos (WEPP) con los sistemas de información geográfica (SIG). GABP-Lab, requiere información espacial (mapas) de clima, suelo, altitud o digital elevation model (DEM) y pendiente (este último derivado del DEM).

El DEM consiste en una distribución de datos de elevación derivados de mapas topográficos, regularmente espaciados en celdas o píxeles dentro del límite de estudio. Esta información permite identificar áreas vulnerables por píxel y así dar un mayor soporte a la distribución espacial generada con el manejo de estas herramientas de simulación.

Gerther *et al.* (2002) señalaron que la distribución espacial de este tipo de información así como los errores propagados, varían de acuerdo a la resolución espacial. Además el control de estos errores depende principalmente de la topografía. En áreas de topografía simple, con pendientes casi planas, una baja resolución quizás no genere grandes errores y puede ser utilizada con poca incertidumbre en estudios como por ejemplo a nivel de cuenca. En cambio en áreas de topografías complejas, con pendientes pronunciadas, una baja resolución puede resultar en grandes incertidumbres, y una resolución más alta es necesaria.

De la Cruz *et al.* (1999) elaboraron un mapa digital para la Cuenca La Encañada – Tambomayo con una resolución espacial (o tamaño de píxel) de 100 m x 100 m, generando así un DEM de suficiente resolución para terrenos complejos como los

Andes. Asimismo, Overmars (1999) elaboró un mapa digital de suelos de alta resolución (1:25, 000) recomendable y útil para el modelamiento.

GABP-Lab, permite, también modificar el uso de la tierra, fechas de siembra y cosecha, tasas de irrigación, y niveles de fertilización nitrogenada. Las salidas son expresadas a nivel espacial, es decir como mapas de promedios, desviación estándar, valores máximos y mínimos de variables como: cosecha, cantidad de precipitación, cantidad de agua irrigada, evapotranspiración, captación de nitrógeno, lixiviación de nitrógeno, pérdida de suelo, escorrentía y tasa de enriquecimiento (Baigorria *et al.* , 2001, Sanchez, 2004, Romero, 2005).

III. METODOLOGIA

3.1 Área de estudio

El área de estudio está localizada en las cuencas de La Encañada - Tambomayo (Figura.1) en los Andes del norte de Perú ($7^{\circ}4' S$, $78^{\circ}16' W$), ocupa un área aprox. de 16500 Ha. ubicadas en un rango de altitud entre 2,950 y 4,000 m.s.n.m. El área de estudio se caracteriza por presentar una topografía muy accidentada, con pobre infraestructura, difícil acceso y muchos riesgos relacionados con el terreno y el clima. Dos regímenes climáticos pueden ser identificados durante el año: una estación lluviosa (septiembre – marzo) y otra seca (mayo-julio). La distribución de la precipitación anual en la cuenca está relacionada a la zona de convergencia intertropical (ZCIT), así como a la intensidad y variación inter anual debido a la ocurrencia de fenómenos como El Niño y La Niña. (Romero, 2004).

Los suelos en el área de estudio han sido clasificados como entisoles, inceptisoles, y molisoles de acuerdo a la clasificación de suelo (USDA-NRCS, 1998). Romero y Stroosnijder (2001) determinaron que el 35% del área presenta gradientes de pendiente mayores al 15% y que gradientes de pendientes mayores a 65% pueden encontrarse. La agricultura está dominada por pasturas (31% del área) y las áreas destinadas a cultivos están sembradas principalmente con raíces andinas y tubérculos (papa, oca y olluco), trigo, cebada, así como pastos naturales y mejorados (Tapia, 1995). La mayoría de los cultivos comerciales son plantados en condiciones de secano antes del inicio de la estación lluviosa (septiembre) aunque esto depende de la disponibilidad de agua, semilla, variedad de cultivo, y el riesgo de heladas. La agricultura en esta área es marginal con un ingreso aproximadamente de 400 a 3,200 dólares por año y hectárea (Valdivia, 2002) siendo el ingreso per cápita es de menos de 1 dólar por día (Baigorria *et al.* , 2002).

La Encañada - Tambomayo




Figura 2. Mapa de ubicación de las cuencas La Encañada - Tambomayo

3.2 MATERIAL

3.2.1 Software CLIMLAB 2000

CLIMLAB 2000 (Tanco y Berry, 1995), es un software de aplicación estadística desarrollado por el International Research Institute for Climate Prediction (IRI). CLIMLAB fue específicamente diseñado para investigación y aplicación práctica de monitoreos y predicción climática estacional. Esta herramienta permite hacer tanto análisis y gestión (cálculo de anomalías y valores estacionales, etc.), presentación de los datos y resultados (gráficos, series temporales, histogramas, gráficos de líneas de contorno, etc) además de análisis estadístico avanzado (Análisis de funciones empíricas ortogonales, correlaciones canónicas). El software cuenta con un registro histórico de datos de temperatura superficial del agua de mar desde 1,949 el cual puede ser actualizado a través de Internet.

3.2.2 Colección de datos

3.2.2.1 Datos de estaciones meteorológicas

Tapia (1995) subdividió la cuenca en tres zonas agroclimáticas (ZAC) denominadas valle ladera, y jalca (Tabla 2). En cada una de estas ZAC, se encuentra localizada una estación meteorológica: La Toma (3,590 m.s.n.m) en la jalca, Usnio (3,260 m.s.n.m) en la ladera, y Manzanas (3,020 m.s.n.m) en el valle. Una de las estaciones más antigua es Usnio con un récord histórico diario de 21 años, mientras que las otras dos tienen un registro de 9 años con datos de series de tiempo de temperatura máxima y mínima, cantidad e intensidad de precipitación y radiación solar.

Tabla 2. Zonas Agroecológicas

Zona	Altura (m.s.n.m)	Superficie (ha)	Porcentaje (%)
Valle	< 3,100	1,244	10.6
Ladera baja	3,100 – 3,200	1,137	9.6
Ladera alta	3,200 – 3,600	6,247	53.1
Jalca	> 3,600	3,160	26.7

Fuente: Sologastua y Muñoz, 1993.

3.2.2.2 Datos de temperatura superficial de agua de mar (TSM)

Teniendo en cuenta que Gilford *et al.* (1992) señalan que la TSM comprendida entre 20°N a 26°S, y de 180 a 60°W influencia fuertemente el clima del norte del Perú y de acuerdo a la información disponible se seleccionó un área del océano pacífico la cual se extiende de 20°N a 25°S y de 60° a 180°W.

Los datos de TSM a nivel global utilizados provienen de dos fuentes: a) CLIMLAB: proporcionó datos mensuales de TSM observados con una resolución de 2° de latitud x 2° de longitud y b) datos mensuales pronosticados de anomalías de TSM, con una resolución de 2° de latitud x 1.5° de longitud.

Para el análisis de los datos de TSM, NOAA utiliza datos *in situ* de TSM (boyas, buques, etc.), imágenes satelitales de TSM además de la TSM simulada a partir de las coberturas de hielo del mar. Antes de hacer el análisis, los datos son ajustados empleando un factor de corrección mediante el método de Reynolds (1988) y Reynolds y Marisco (1993) (National Centers for Environmental Prediction, 2001).

3.2.3 Recopilación de información sobre el manejo de cultivos

Las principales variables consideradas en la evaluación del manejo de cultivo son a) tipo de cultivos, b) niveles de fertilización nitrogenada y c) fechas de siembra. La interrelación de estas tres variables es considerada en los escenarios de simulación planteados para ser ejecutados en DSSAT.

En este trabajo de investigación se dará énfasis al cultivo de papa, ya que la papa es uno de los cultivos principales y de mayor distribución en el área de estudio. La información que se empleó fue obtenida y evaluada por el proyecto “Relaciones de intercambio entre agricultores y medio ambiente” (Valdivia, 2002).

3.2.4 Herramientas de simulación

- DSSAT (Sistemas de apoyo a las decisiones para la transferencia de agrotecnología): Modelo de cultivos (Jones, 1990).

- GABP-LAB (GIS and Bio-Physical Modeling Laboratory):

Herramienta de Integración y visualización de la información. (Baigorria, 2001).

3.2.5 Mapas utilizados en la simulación de GABP-Lab

3.2.5.1 Mapas de clima

En trabajos de investigación anteriores se desarrollaron técnicas de interpolación basadas en procesos que permitieron estimar la distribución espacial de las variables de temperatura máxima, temperatura mínima y precipitación; además de un modelo empírico para estimar la radiación solar a nivel puntual. (Baigorria *et al.*, 2004; Baigorria, 2005). Es así como se pudieron obtener los siguientes mapas:

A. Mapas de radiación solar incidente

Estos mapas fueron obtenidos a partir de un modelo empírico desarrollado para estimar la radiación solar incidente a nivel puntual (Bristol y Campbell, 1984). Dicho modelo fue calibrado y validado para el Perú por Baigorria *et al.*, (2004) y aplicado en la cuenca La Encañada y Tambomayo. Las fórmulas obtenidas en función a la temperatura permitieron posteriormente su aplicación a nivel espacial.

B. Mapas de temperatura máxima y mínimas

Se desarrollaron a partir de un modelo que permite la interpolación de temperaturas máximas y mínimas, el cual fue calibrado y validado en la cuenca La Encañada y Tambomayo (Baigorria *et al.*, 2001b). Este modelo fue utilizado para elaborar los mapas de temperaturas diarias a nivel espacial, así mismo empleando las fórmulas empíricas del modelo anterior se pudo estimar la radiación solar a nivel espacial (Baigorria *et al.*, 2004).

C. Mapas de precipitación

Estos mapas se obtuvieron empleando un modelo, desarrollado para estimar la distribución espacial de la precipitación (Baigorria *et al.*, 2000b), el cual fue probado y validado también en las microcuencas de La Encañada - Tambomayo (Baigorria *et al.*, 2003a).

3.2.5.2 Mapas de suelos

Se utilizó un mapa digital de suelos a escala 1:25,000, como información base en el presente trabajo. Este mapa desarrollado por Overmars (1999), clasifica el suelo en horizontes funcionales (en base a su función y no a su génesis) según la evaluación de los perfiles del suelo. La ventaja de su uso es su alta resolución, lo que lo hace aplicable al modelo. El mapa fue obtenido en base a un muestreo del suelo, el cual fue relacionado con la topografía y fisiografía del lugar, con la idea de predecir el perfil típico del suelo en diferentes puntos del área de estudio.

3.2.5.3 Mapas de pendientes

El mapa de pendientes fue generado por De la Cruz *et al.*, (1999), a partir de la digitalización de las curvas de nivel de la zona en estudio, las que a su vez, fueron llevadas a un modelo de elevación digital (DEM), con una resolución de 50 x 50 m.

3.3 METODOS

El método a seguir consiste en estimar variables meteorológicas en función de la temperatura superficial de agua de mar (TSM) realizando una desagregación espacial y temporal de la información disponible, mediante la aplicación de regresiones múltiples (Figura 3), para luego integrar esta información con modelos biofísicos obteniendo resultados que permitan apoyar en las decisiones agrícolas.

3.3.1 División de la base de datos de clima a nivel de Estación Meteorológica

Los registros de datos disponibles para cada estación fueron divididos en dos subconjuntos de datos. El 66% del record histórico mensual disponible de cada estación

2316



fue usado en la calibración del modelo, mientras que el resto de los datos en la validación y comparación del mismo. Así, el período comprendido entre 1995 y 1998 y el de 1999 al 2000 fue utilizado en la calibración y validación respectivamente, para las estaciones La Toma y Manzanas, mientras que en el caso de Usnio, al poseer un mayor récord de información, se procedió a dividir los datos de la siguiente manera 1992-1997 en la calibración y 1998-2000 en la validación del modelo. Asimismo, fue necesario un ordenamiento de los datos meteorológicos en el formato requerido por el software CLIMLAB, para su posterior análisis.

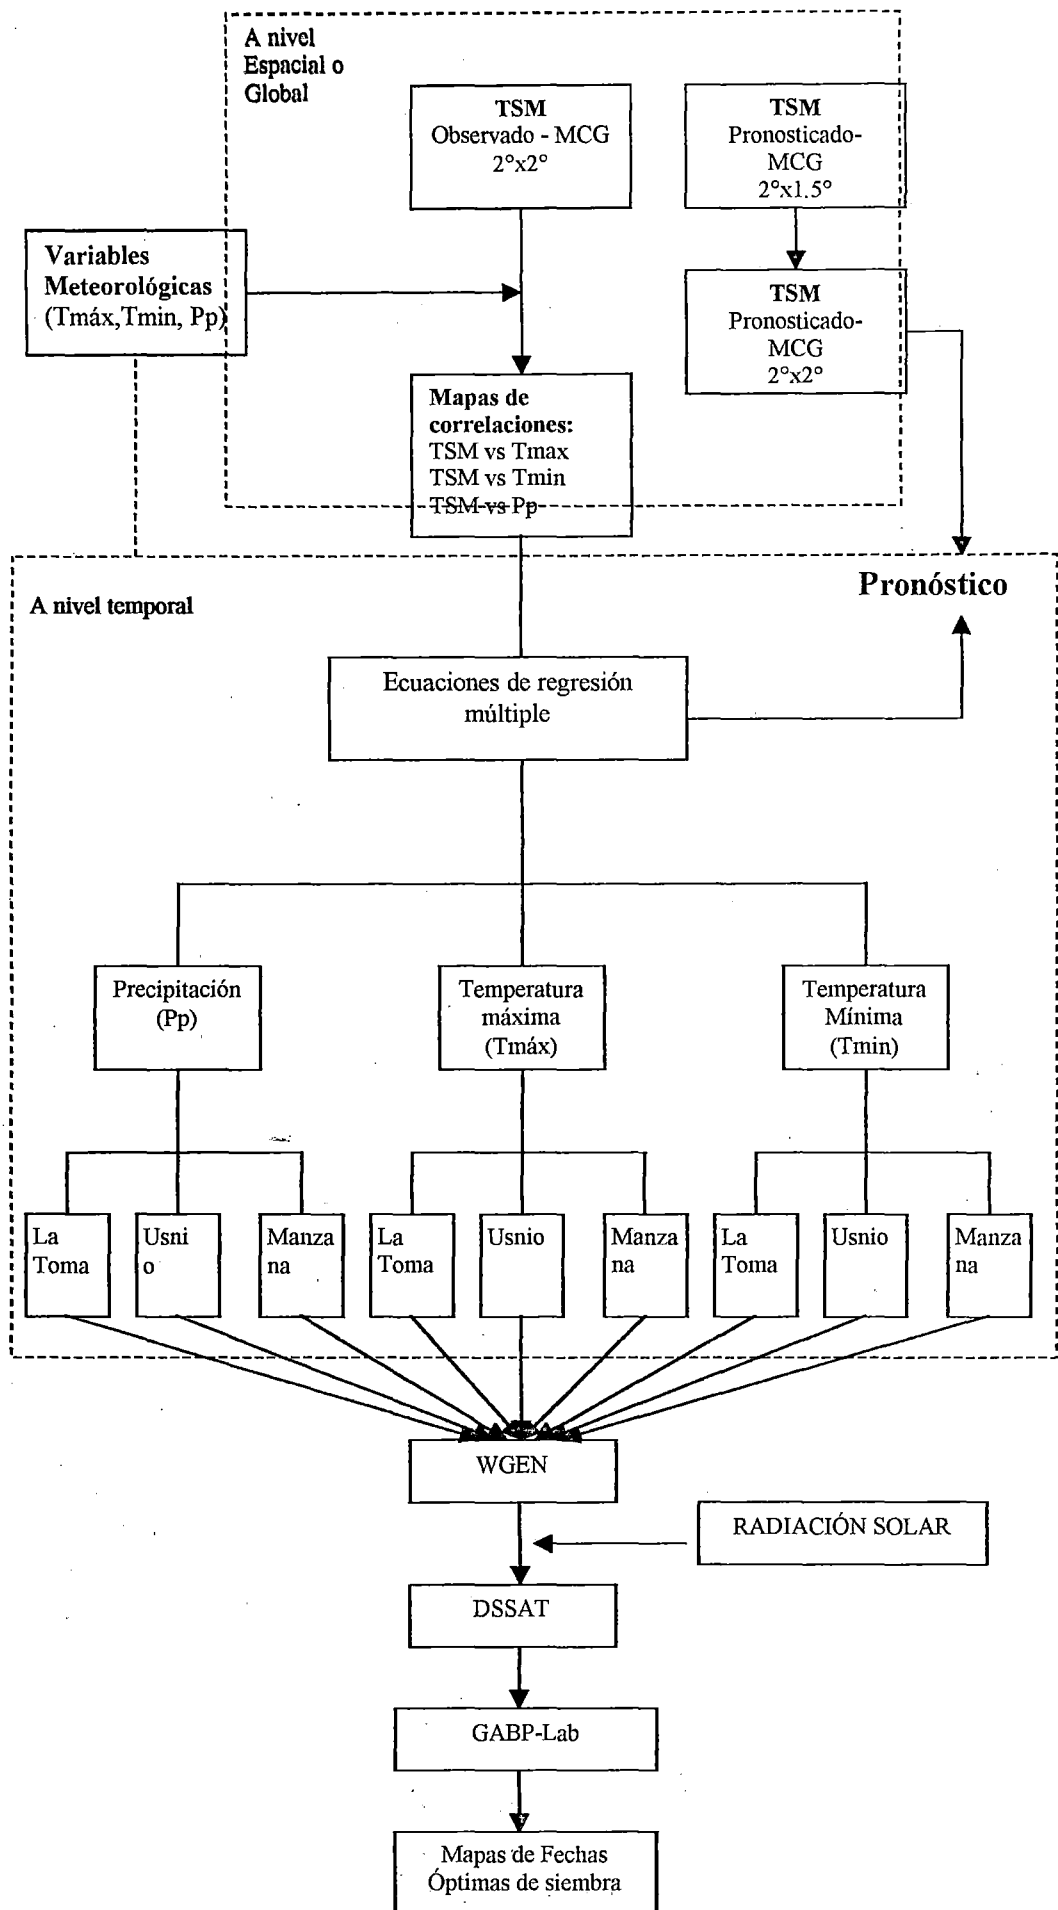


Figura 3. Diagrama de flujo de metodología desarrollada para el pronóstico de variables meteorológicas como apoyo a las decisiones agrícolas

3.3.2 Desagregación espacial del MCG

3.3.2.1 Estandarización de resoluciones de información observada y del pronóstico de TSM

Los datos observados de TSM así como los pronosticados deben tener una misma resolución espacial y temporal, es por esto que las series de tiempo de los mapas de pronóstico fueron espacialmente estandarizados en el eje longitudinal agregando pares de píxeles adyacentes y aplicando un método de interpolación (Isaaks y Srivastava, 1989).

3.3.2.2 Análisis de los datos meteorológicos y de la temperatura superficial de agua de mar (TSM)

El establecimiento de los coeficientes de correlación entre la TSM y las variables meteorológicas de precipitación y temperatura permitieron responder a la primera parte de la hipótesis planteada sobre la incidencia de la TSM en la variabilidad climática estacional. Los pasos para la obtención de estos coeficientes se detallan a continuación.

Los datos observados de TSM registrados en un píxel de tamaño $2^{\circ} \times 2^{\circ}$ fueron correlacionados con cada una de las series de tiempo disponible para cada variable y estación meteorológica dentro del área de estudio correspondiente. Cada píxel representa el promedio de tres meses de TSM observada, donde cada uno de estos valores a nivel espacial fue correlacionado de manera independiente con series de tiempo correspondiente a temperatura máxima, mínima y precipitación de cada estación meteorológica. Esto produjo como resultado coeficientes de correlación entre TSM y el clima con un rezago de tiempo de tres meses (ejemplo TSM de julio a setiembre versus precipitación de octubre).

Estos coeficientes de correlación (R) determinaron un área específica del mar, pudiendo entonces expresarse R como:

$$R = f(TSM_{\phi, \lambda}) \quad [1]$$

donde,

ϕ : latitud y,

λ : longitud

Los coeficientes de correlación (R) obtenidos se georeferenciaron formando mapas de índices de correlación. En la Figura 3, se observan las pautas seguidas para la generación de los mapas de correlación y la extracción de los datos de TSM utilizados en el análisis de regresión múltiple.

3.3.2.3 Matriz de correlación

Con los R georeferenciados y formando mapas de índices de correlación (figura 4b) para cada variable meteorológica a nivel mensual, se determinaron aquellas áreas donde los más altos valores de R explicaron una mayor proporción de la varianza, siendo seleccionados por su alta covariabilidad y como posibles estimadores de variables meteorológicas mensuales. Entonces muy similar a la expresión [1] se tiene que:

$$TSM_i = \frac{\sum_{\substack{k=\lambda_m \\ j=\phi_n}} TSM_{j,k}}{N_{n \times m}} \quad [2]$$

donde

ϕ_1 = latitud del píxel inicial del área j

ϕ_n = latitud del píxel final del área j

λ_1 = longitud del píxel inicial del área j

λ_n = longitud del píxel final del área j

N_{pxm} = número de píxeles del área j

Con la ayuda de CLIMLAB se extrajeron los valores promedios de TSM correspondientes a una determinada latitud y longitud a partir de áreas previamente limitadas por los coeficientes de correlación, y con estos datos espaciales se construyeron matrices ordenadas en filas y columnas de años y meses respectivamente.

3.3.2.4 Análisis de regresión múltiple

El análisis de regresión múltiple consiste en la extensión del análisis de regresión simple, a cualquier número de variables, donde una es considerada como dependiente y las demás como independientes. (Sierra, 1994).

Se trata de encontrar la ecuación que exprese mejor, matemáticamente, la relación de los valores de una variable dependiente, Y, con los valores de dos o más variables independientes, X_1, X_2, X_3, \dots

Entonces la expresión matemática tiene la siguiente fórmula:

$$Y = f(X_1, X_2, X_3, \dots, X_n) \quad [3]$$

En este caso, en particular, la metodología desarrollada permitió predecir datos de estaciones meteorológicas a partir de información espacial de TSM, donde la variable dependiente, "Y", son las series de tiempo de datos mensuales de precipitación, temperatura máxima y temperatura mínima de las tres estaciones utilizadas en el área de estudio, mientras que las variables independientes son los promedios de series de tiempo de temperatura de agua de mar (TSM) para pequeñas áreas seleccionadas en el Océano Pacífico¹ (20N-25S; 60S-180S).

¹ Áreas específicas seleccionadas de los mapas de correlación obtenidos entre los datos meteorológicos y TSM.

y1	A1 +	A1 +	+	+
y2	A1 +	A1 +	+	+
y3	+	+	A2 +	A2 +
y4	+	+	A2 +	A2 +
y5	+	+	+	+
y6	+	+	+	+
	x1	x2	x3	x4

(a)

Matriz de correlación obtenida entre los datos de TSM a nivel espacial y la información climática para cada píxel. Las celdas sombreadas representan áreas formadas.

y1	0.8 +	0.8 +	0.3 +	-0.2 +
y2	0.8 +	0.8 +	0.1 +	0.1 +
y3	0.2 +	0.2 +	0.7 +	0.9 +
y4	0.1 +	0.3 +	0.9 +	-0.6 +
y5	-0.3 +	0.1 +	0.2 +	0.2 +
y6				
	x1	x2	x3	x4

(b)

Los coeficientes de correlación determinaron áreas específicas del mar. Donde los más altos valores fueron seleccionados para construir las ecuaciones de pronóstico, mediante un modelo de regresión múltiple.

y1	20.5 +	18.5 +	20.3 +	20.2 +
y2	15.4 +	22.3 +	19.7 +	21.5 +
y3	20.7 +	22.3 +	20.4 +	21.5 +
y4	23.2 +	20.7 +	20.4 +	19.9 +
y5	20.5 +	23.2 +	20.2 +	20.1 +
y6				
	x1	x2	x3	x4

(c)

Extracción de áreas específicas del mar para obtener datos promedios de TSM de cada una de los pixeles involucrados.

Figura 4. Procedimientos de formación de áreas de correlación y extracción de TSM a nivel espacial.

Entonces la ecuación [3] puede ser expresada por:

$$Y = f(TSM_1, TSM_2, TSM_3, \dots TSM_n) \quad [4]$$

Donde los sub índices de TSM representan las diferentes áreas georeferenciadas del mar, con datos promedios de TSM. De todas estas áreas seleccionadas de los mapas de correlación solo se consideraron aquellas áreas que pudieron explicar una alta proporción de la varianza en la variable dependiente. En el presente trabajo muchas veces se seleccionó más de un área del mar que explicó una alta proporción, por ejemplo, para el caso específico de una regresión múltiple con dos variables independientes se tiene que:

$$Y = a + b TSM_1 + c TSM_2 \quad [5]$$

Para seleccionar la mejor combinación de las variables independientes se tomó en cuenta el mayor coeficiente de regresión, y el menor error cuadrático medio (ECM) con un nivel de significancia (α) de 0.05. Los resultados de estas áreas georeferenciadas se muestran en los anexos 2-4.

Las áreas georeferenciadas fueron obtenidas con un rezago de tiempo de tres meses (ejemplo TSM de julio a setiembre (JAS) versus precipitación de octubre (OCT)). Como en la ecuación siguiente:

$$Pp_{OCT} = a + a_1 TSM_{JAS} + a_2 TSM_{JAS} + a_3 TSM_{JAS} + \dots \quad [6]$$

$$Tx_{OCT} = b + b_1 TSM_{JAS} + b_2 TSM_{JAS} + b_3 TSM_{JAS} + \dots \quad [7]$$

$$Ti_{OCT} = c + c_1 TSM_{JAS} + c_2 TSM_{JAS} + c_3 TSM_{JAS} + \dots \quad [8]$$

Donde:

Pp : precipitación

Tx : temperatura máxima del aire;

Ti : temperatura mínima

TSM_{ijk} : corresponde a los datos de TSM, donde las iniciales de los sub índices representan los meses utilizados en el pronóstico.

3.3.2.5 Calibración

Con los datos, previamente estandarizados y ordenados por año y mes, las variables meteorológicas (66% de los datos disponibles) y los promedios de TSM obtenidos de áreas específicas del mar, se construyeron las ecuaciones de regresión múltiple con la ayuda de CLIMLAB.

Las ecuaciones encontradas en función de TSM permitieron estimar la variabilidad climática estacional para cada ZAC a nivel mensual.

3.3.2.6 Validación

La validación de la metodología se efectuó con el 33% de datos restantes, para lo cual se realizó una comparación entre la serie estimada y observada correspondientes a las variables de precipitación, temperatura máxima y mínima para cada estación meteorológica.

El modelo fue evaluado a través del cálculo del coeficiente r de Pearson, el análisis de residuales, y terciles de residuales que permitieron explicar posibles incertidumbres en el modelo. Además, el análisis de significancia ($\alpha < 0.05$) fue evaluado para cada ecuación de pronóstico mensual obtenida.

3.3.3 Aplicación

Mediante las ecuaciones encontradas para la predicción de temperatura del aire y precipitación en la cuenca La Encañada–Tambomayo (Anexo 5), es posible predecir la variabilidad climática estacional en los próximos meses, si la TSM para estos meses es disponible.

3.3.3.1 Uso de TSM pronosticado

Los pronósticos de TSM para meses próximos se obtuvieron de la página web de la NOAA (<ftp://ftp.ncep.noaa.gov/pub/cmb/Forecasts/enso>), y así se determinaron los valores de precipitación y temperatura del aire a nivel mensual para el período 2003 – 2004 en cada estación meteorológica o ZAC. Para esto se alimentaron las ecuaciones encontradas mediante el análisis de regresión múltiple con los pronósticos de TSM producidos por NOAA previamente estandarizados según el punto 4.3.2.1

3.3.3.2 Desagregación temporal de los pronósticos climáticos estacionales

Los pronósticos mensuales de temperatura máxima y mínima del aire así como de precipitación para cada estación meteorológica obtenidos con los pasos previos son desagregados a nivel diario utilizando el Weather Generator – WGEN (Richardson y Wright, 1984). Los requisitos necesarios para ejecutar el WGEN son:

- a) promedios mensuales pronosticados de las variables en estudio
- b) desviación estándar mensual de la temperatura máxima, radiación solar en días secos y húmedos, temperaturas mínimas y precipitación
- c) parámetro escalar de la distribución de la precipitación
- d) la probabilidad de secuencias de días secos a húmedos, y
- e) el número total de días de precipitación

Los puntos b, c, d y e fueron calculados por el modelo de Bristow Campbell (Senamhi – MEM, 2003, Baigorria *et al.*, 2004) a partir de los datos de pronóstico de temperatura máxima y mínima del aire, para cada estación meteorológica.

Una vez que se obtuvieron estos datos se generaron 99 archivos con información de temperatura máxima, temperatura mínima, precipitación y radiación solar. Cada archivo representa un año con información diaria de las variables ya mencionadas, permitiendo trabajar no solo con un año de datos generados, sino con una distribución de datos producto de las 99 repeticiones. Esto permitió calcular los promedios y desviación estándar para 99 escenarios de simulación y así dar soporte al análisis de variabilidad.

3.3.4 Integración de la información de clima y las herramientas de simulación

SUBSTOR (Ritchie *et al.* 1995) es un modelo puntual que se encuentra disponible dentro de DSSAT, dicha herramienta, junto con información de la variabilidad climática estacional a nivel diario e información de suelo, estimó producción del cultivo de papa en tn/ha bajo diferentes escenarios de simulación ya establecidos (fechas de siembra, dosis de nitrógeno). Aquí se encontró que los mayores valores de producción correspondieron a las fechas de siembra de octubre a enero, constituyéndose así las fechas de simulación para la generación de los mapas de fechas óptimas de siembra. Hasta aquí se logra responder totalmente a la hipótesis planteada donde los datos de TSM se tradujeron en datos de precipitación y temperatura del aire, esto explicado por la incidencia de la TSM en la variabilidad climática estacional y finalmente esta información de precipitación, temperatura, y otras requeridas por DSSAT permitieron establecer las fechas de siembra y con el manejo integrador del Gabp-Lab generar los mapas de fechas óptimas de siembra.

3.3.4.1 Mapas de fechas óptimas de siembra

Los mapas de fechas óptimas de siembra constituyen los mayores valores de producción encontrados para el cultivo de papa dentro de los meses simulados (octubre – enero). Estos cálculos fueron determinados por DSSAT. Los meses simulados no solo representan la mayor producción de papa sino también el periodo de mayor precipitación. Además que los coeficientes de correlación determinados entre precipitación-TSM y temperatura-TSM tienden a ser los más altos dentro de este periodo justificando así no solo la incidencia de la TSM en la variabilidad climática sino también la mejor aproximación en la predicción dentro de este periodo (Figura 5). Cabe

señalar que el riesgo a la sequía y heladas son dos factores que afectan gravemente a las zonas altoandinas poniendo en riesgo sus cultivos y estos riesgos pueden ser evaluados a través de la precipitación y temperatura mínima desde que muestran su dependencia con la TSM, aunque esto no es el objetivo del presente trabajo de investigación.




Figura 5. Distribución temporal de coeficientes de correlación (R) entre temperatura-TSM y precipitación-TSM.

GABP-Lab es un modelo de simulación espacial, que emplea información espacial de clima, suelos, topografía y manejo (escenario de simulación) y la transforma a nivel puntual (píxeles de 30 x 30), luego realiza un procesamiento estadístico obteniendo valores promedio, para finalmente agregar la información espacialmente en programas de SIG produciendo un “upscaling” espacial. Entre DSSAT y GABP-Lab se realiza una integración espacio-temporal generando mapas de fechas óptimas de siembra y, el rango de producción bajo estas condiciones. Se hizo un traslape de todos los mapas promedios para las diferentes fechas de siembra y se seleccionó el mes de mayor producción por cada píxel, generando, finalmente, mapas de fechas óptimas de siembra para la cuenca La Encañada – Tambomayo entre los meses de octubre del 2003 y enero del 2004.

IV. RESULTADOS Y DISCUSION

Cuadro 1. Coeficientes de correlación mensual (R) para las tres variables meteorológicas de cada estación. En los paréntesis van las iniciales de los meses de pronóstico de TSM (*)

Variabes meteorológicas	Set. (JJA)	Oct. (JAS)	Nov. (ASO)	Dic. (SON)	Ene. (OND)	Feb. (NDE)	Mar. (DEF)
La Toma							
Temperatura máx.	0.57	0.85	0.96	0.86	0.77	0.78	0.96
Temperatura min.	0.91	0.96	0.41	0.48	0.90	0.93	0.90
Precipitación	0.78	0.66	0.76	0.75	0.81	0.95	0.83
Usnio							
Temperatura máx.	0.35	0.45	0.65	0.48	0.68	0.42	0.56
Temperatura min.	0.43	0.81	0.42	0.61	0.42	0.31	0.46
Precipitación	0.52	0.51	0.26	0.54	0.27	0.55	0.40
Manzanas							
Temperatura máx.	0.97	0.87	0.96	0.78	0.90	0.88	0.77
Temperatura min.	0.79	0.84	0.68	0.78	0.94	0.86	0.84
Precipitación	0.75	0.52	0.45	0.82	0.95	0.42	0.45

(*) tres meses previos

4.1 Calibración

Con respecto al primer objetivo del presente trabajo en el Cuadro 1 se muestra los coeficientes de correlación (R) por cada estación obtenida entre los datos de TSM con precipitación y temperatura del aire. Estas correlaciones fueron obtenidas con el 66 % del record histórico de datos meteorológicos y de TSM. Estos coeficientes (R) se obtuvieron a partir de los mapas que se muestran en la Figura 6. Estos R corresponden a un área específica del Océano Pacífico y representan datos promedios de TSM, las mismas que fueron georeferenciadas y funcionaron como estimadores de las variables meteorológicas. En los Anexos 1, 2 y 3 se muestra la georeferenciación de cada una de las áreas seleccionadas de los mapas de correlación. Es así que los (R) explican el grado de covariabilidad entre TSM y determinada variable meteorológica, mostrando un cierto grado de respuesta entre la variabilidad climática estacional y la TSM. Es decir aquí se puede observar cierta incidencia de la TSM en la variabilidad climática estacional, la cual es medida a través de la precipitación y temperatura como se observa en el cuadro 1. Aquí se responde claramente a la primera parte de la hipótesis planteada sobre la incidencia de la TSM en la variabilidad climática estacional. Estas relaciones permitieron construir los modelos de regresión múltiple. Los métodos estadísticos son capaces de hacer una mayor contribución cuando los índices de TSM, están claramente establecidos. Como lo señaló Bierkens *et al.* (2002), la ventaja de seleccionar un número mayor de variables expresa la incertidumbre acerca de la verdadera variación de la propiedad que está siendo medida. Pero también esto puede no ser significativo y más bien agregar mayor incertidumbre, ya que seleccionar un número mayor de variables con el fin de obtener la mejor correlación tiende a una curva asintótica.

Los principales parámetros estadísticos tomados en cuenta en la selección de las ecuaciones de pronósticos para las tres estaciones meteorológicas se resumen también en los Anexos 1, 2 y 3. Los coeficientes de correlación obtenidos responden a un error cuadrado medio (ECM) y un nivel de significancia (α) de 0.05.

Una de las condiciones de superficie más importante que afecta la variabilidad climática es la TSM, y es así que la habilidad en predecir valores totales estacionales o promedios climáticos, a veces va asociada con los patrones de circulación atmosférica que tienen su origen en el cambio lento de las condiciones de superficie (como TSM) y que pueden influenciar el clima. Así *White et*

al. (1997) encontraron que las anomalías en la TSM son altamente correlacionadas (> 0.9) con patrones globales de anomalías de precipitación sobre continentes adyacentes en escalas de tiempo interanuales. Es por tal razón que se consideró necesario tener en cuenta que la influencia de TSM en la variabilidad climática se da con un rezago de tiempo de tres meses. Esto explica porqué las ecuaciones de pronóstico que se muestran en el Anexo 4 están en función de TSM con un período de tres meses de anterioridad con respecto a la variable meteorológica de interés y porqué los R^2 mensuales del Cuadro 1 fueron obtenidos, de igual manera, con datos de TSM de meses diferentes.

Es de conocimiento que la exactitud de los pronósticos disminuye a medida que se incrementa el tiempo entre el pronóstico y la fecha a pronosticar, entonces realizar pruebas de pronósticos con mayor período de anticipación agregaría una mayor incertidumbre al modelo. Cabe agregar que se desconoce que exista un forzamiento en el Océano Pacífico con un período de seis meses, ya que la onda Kelvin responsable de esta propagación sobre el pacífico oriental es bastante rápido y dura menos de tres meses (Cane, 1992).

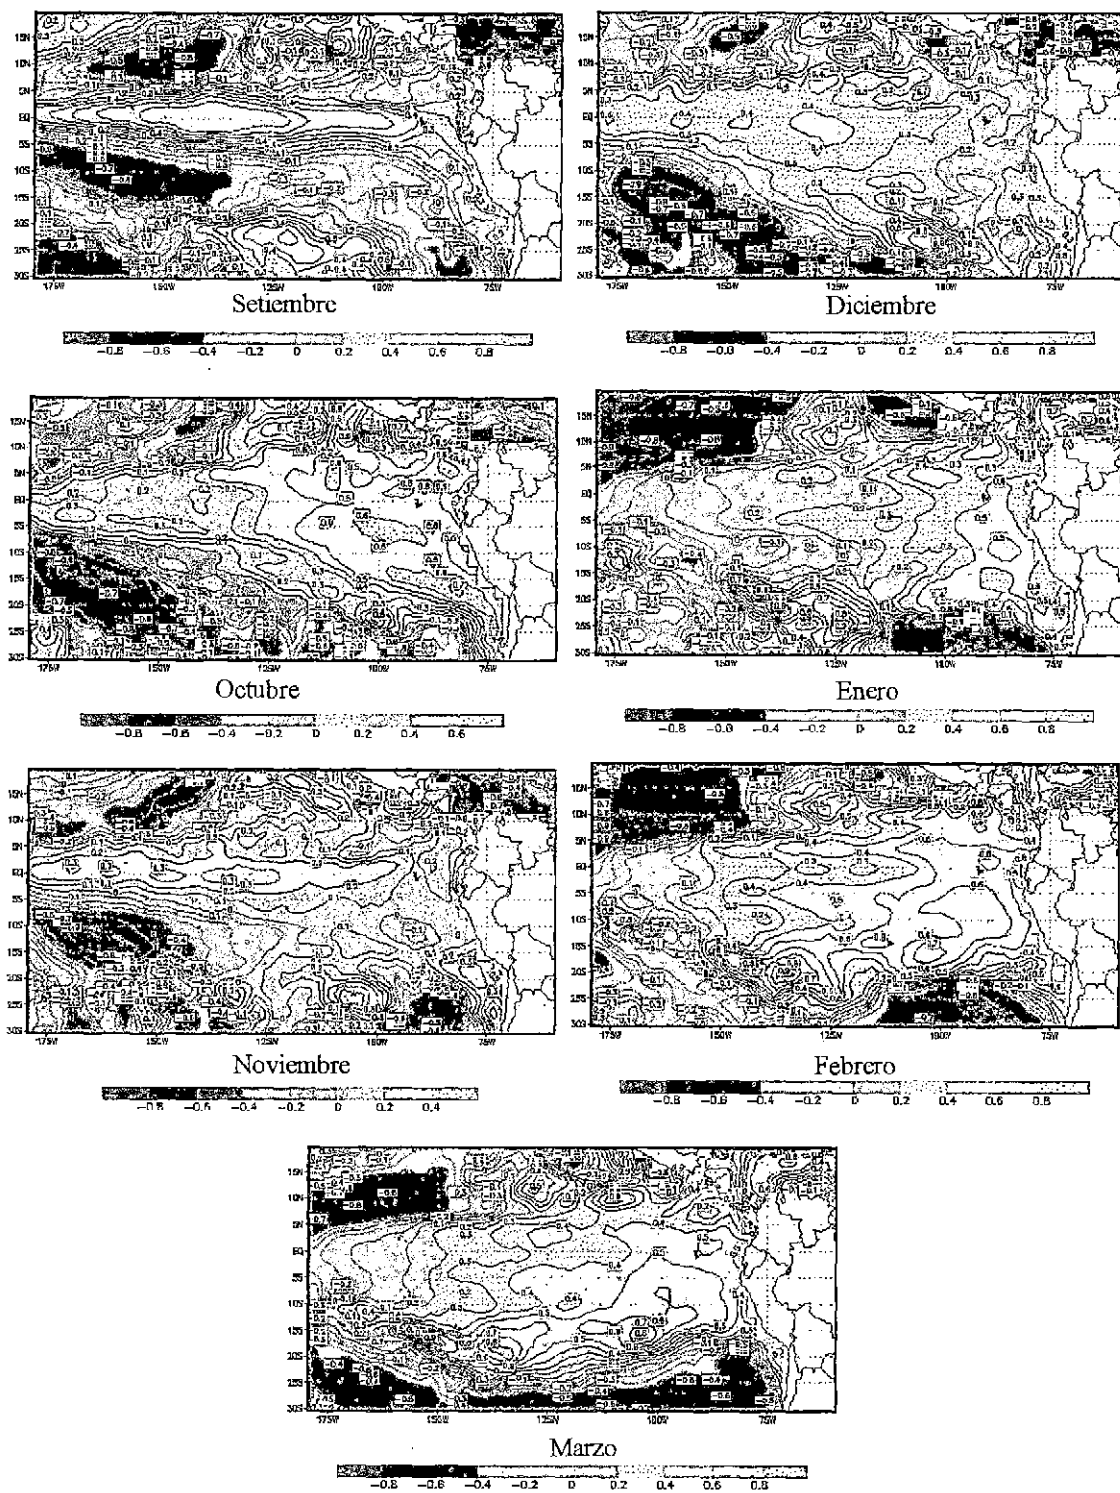


Figura 6. Mapas de correlación entre TSM vs Temp. máxima - Estación Manzana obtenidos durante el proceso de calibración.

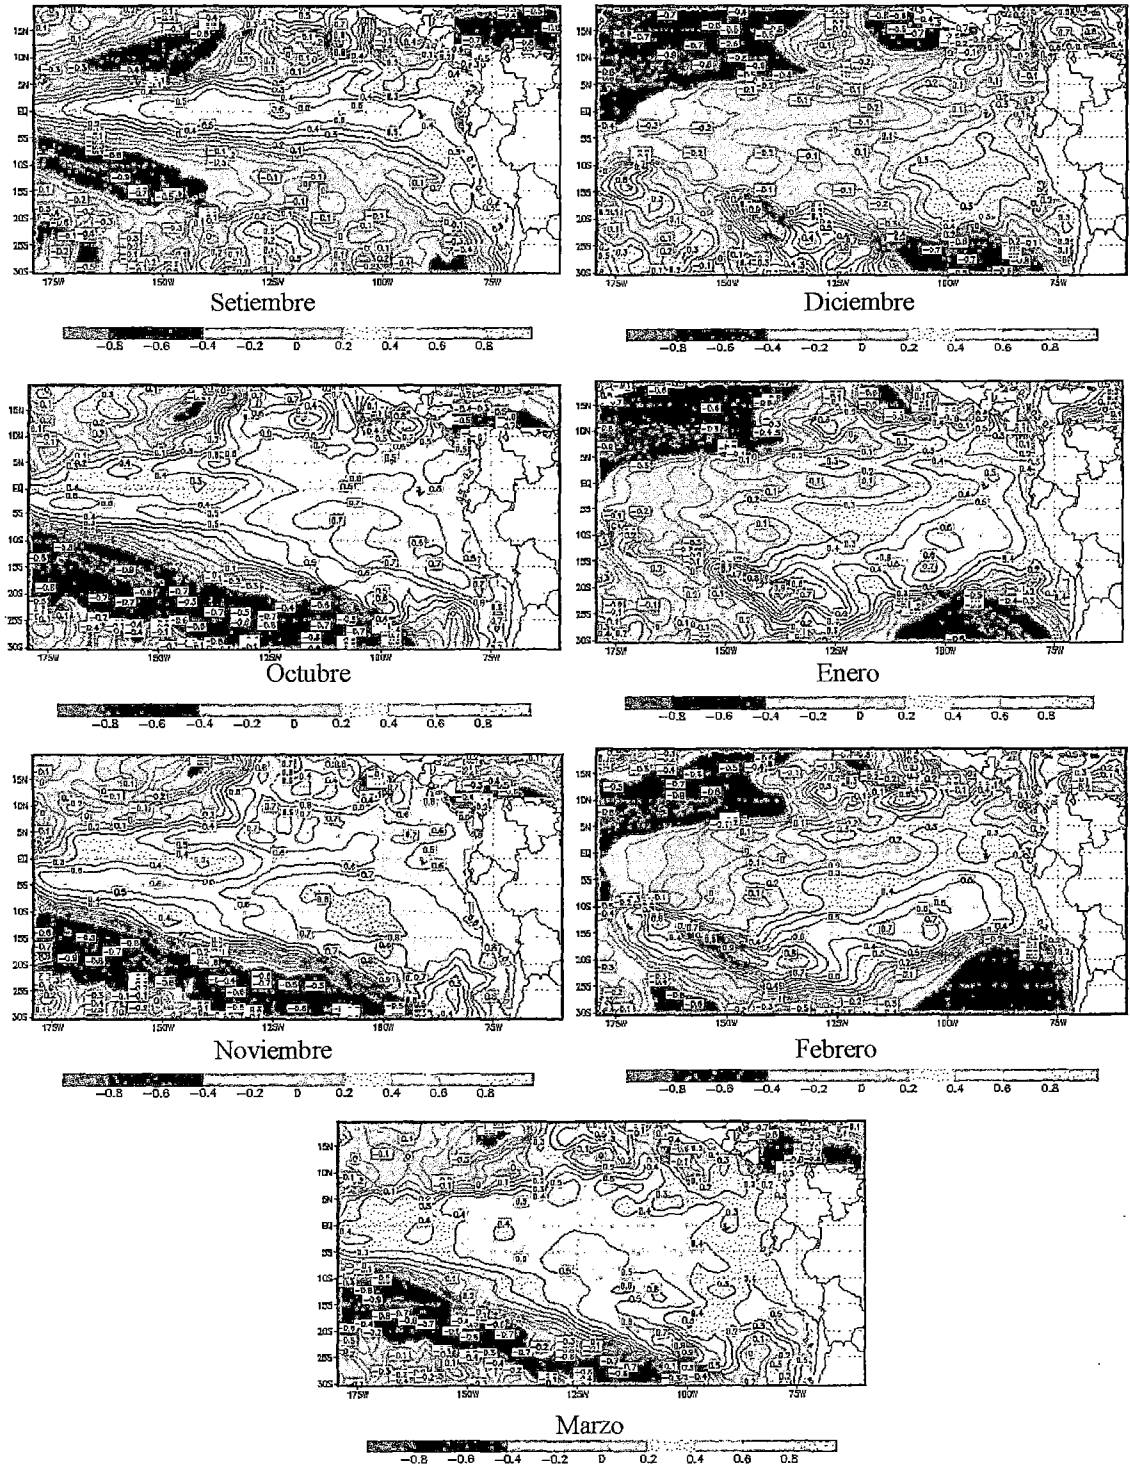


Figura 7. Mapas de correlación. TSM vs Temperatura mínima. Estación – Manzana obtenidos durante el proceso de calibración.

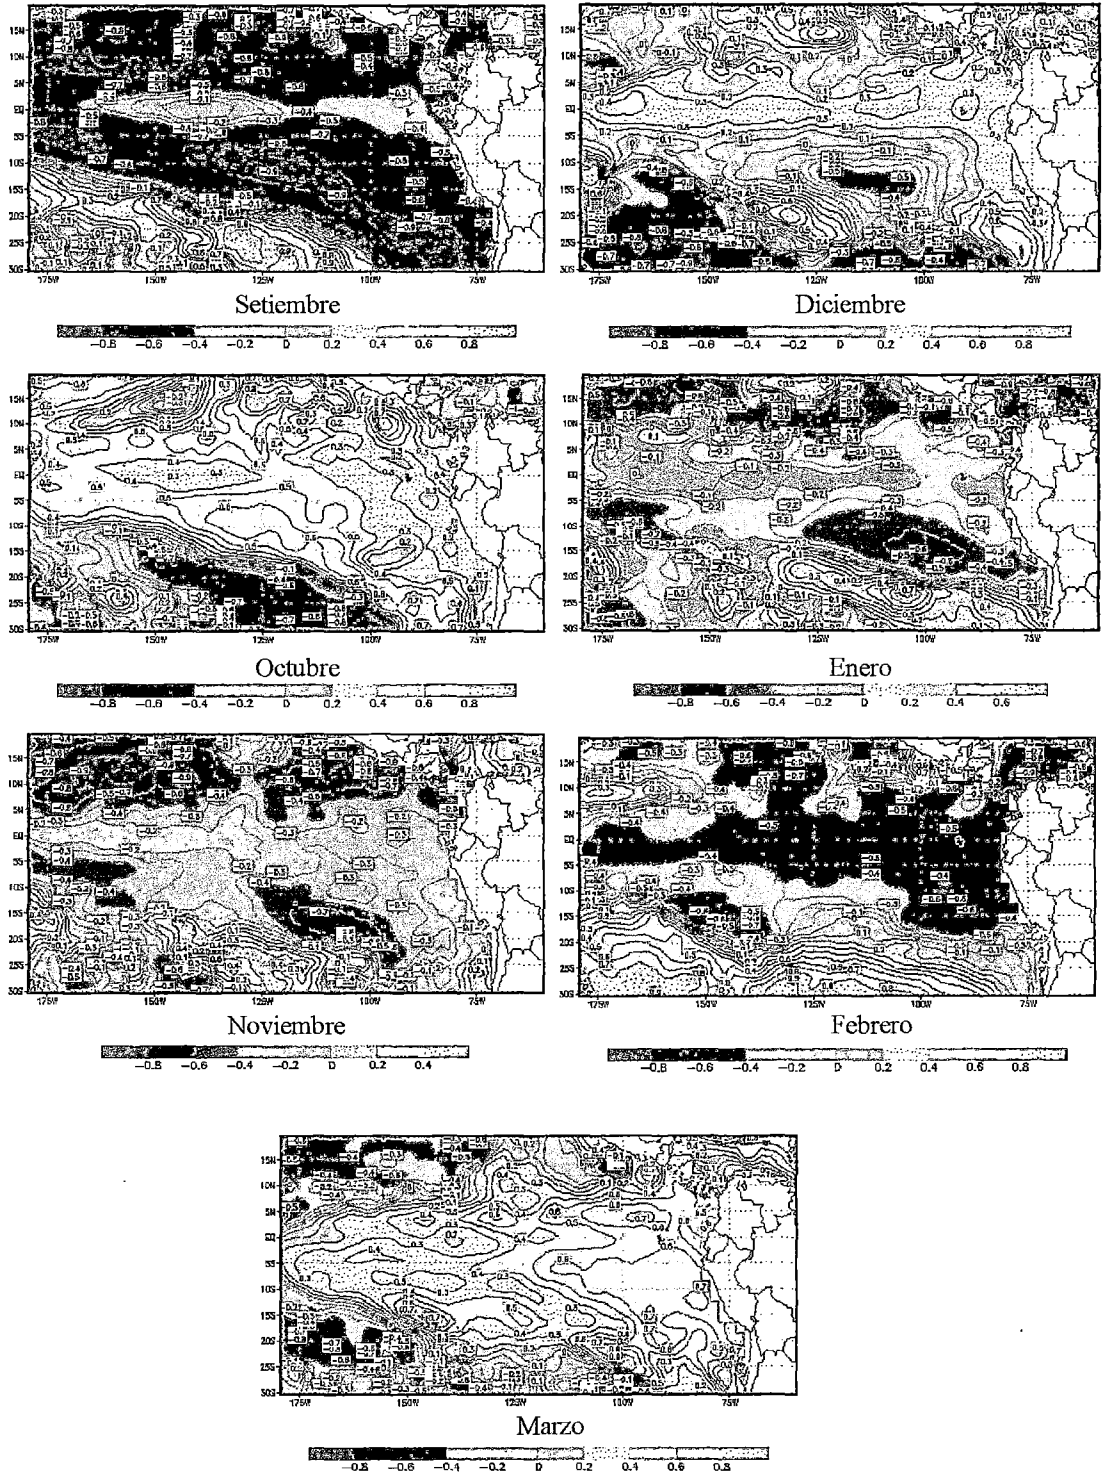


Figura 8 Mapas de correlación. TSM vs Precipitación. Estación-Manzana obtenidos durante el proceso de calibración.

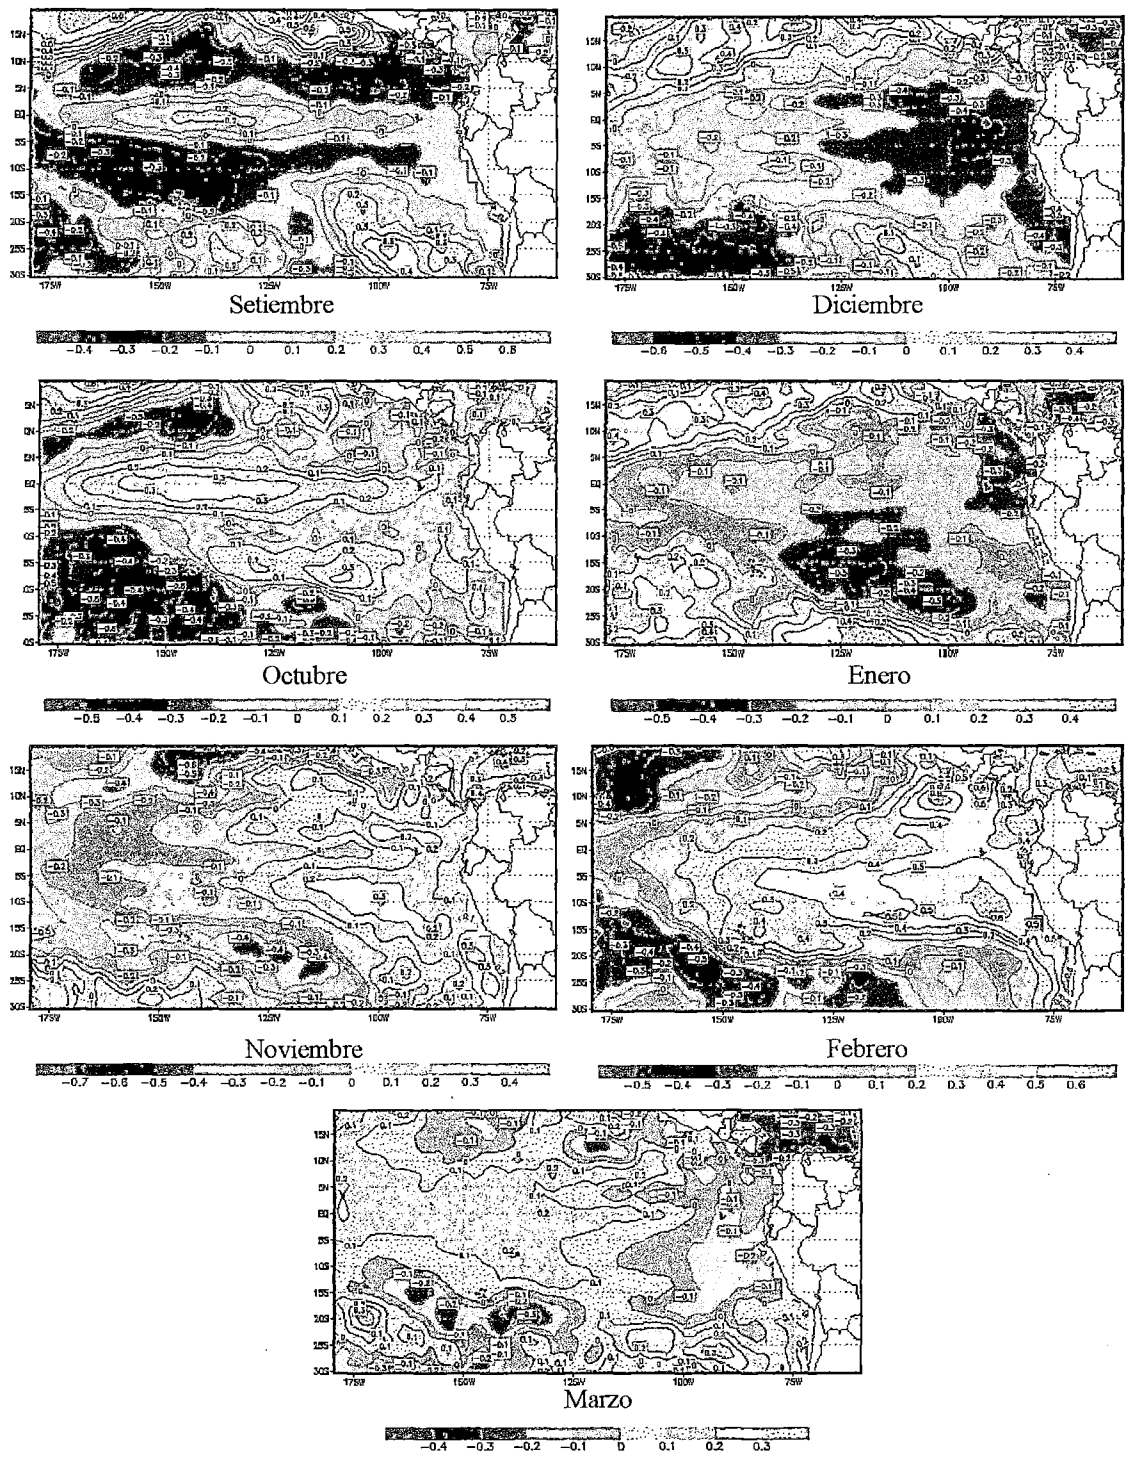


Figura 9. Mapas de correlación. TSM vs Temp máxima. Estación-Usnio obtenidos durante el proceso de calibración.

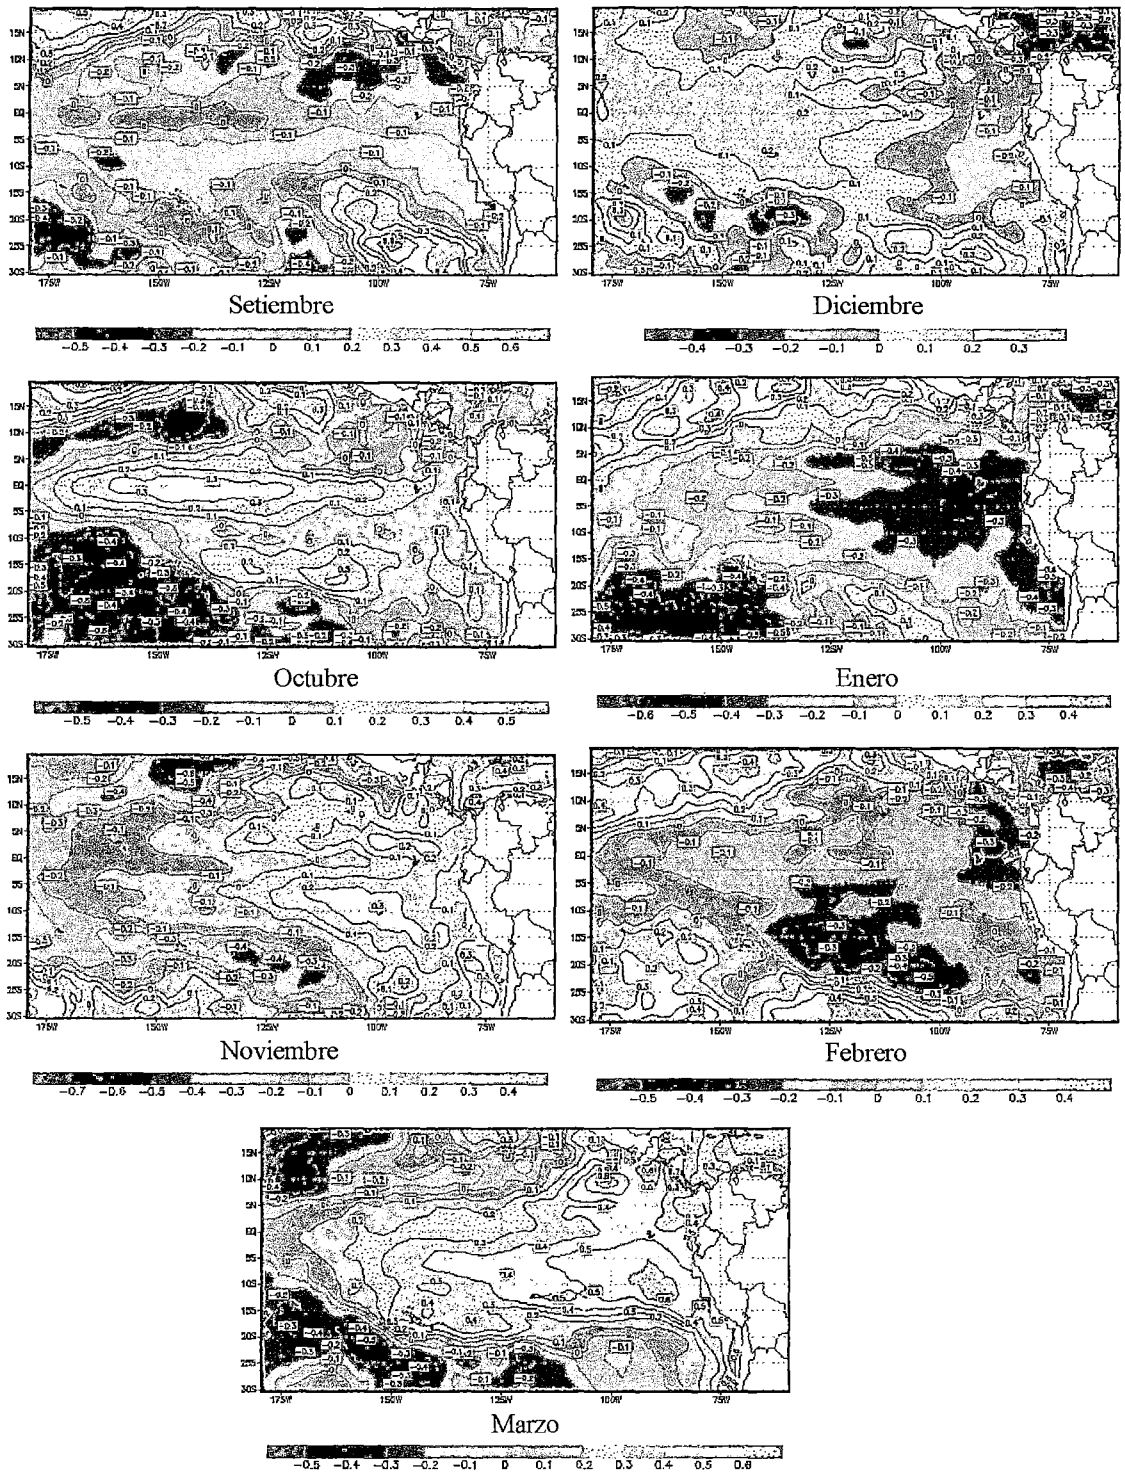


Figura 10. Mapas de correlación. TSM vs Temp. mínima. Estación-Usnio obtenidos durante el proceso de calibración.

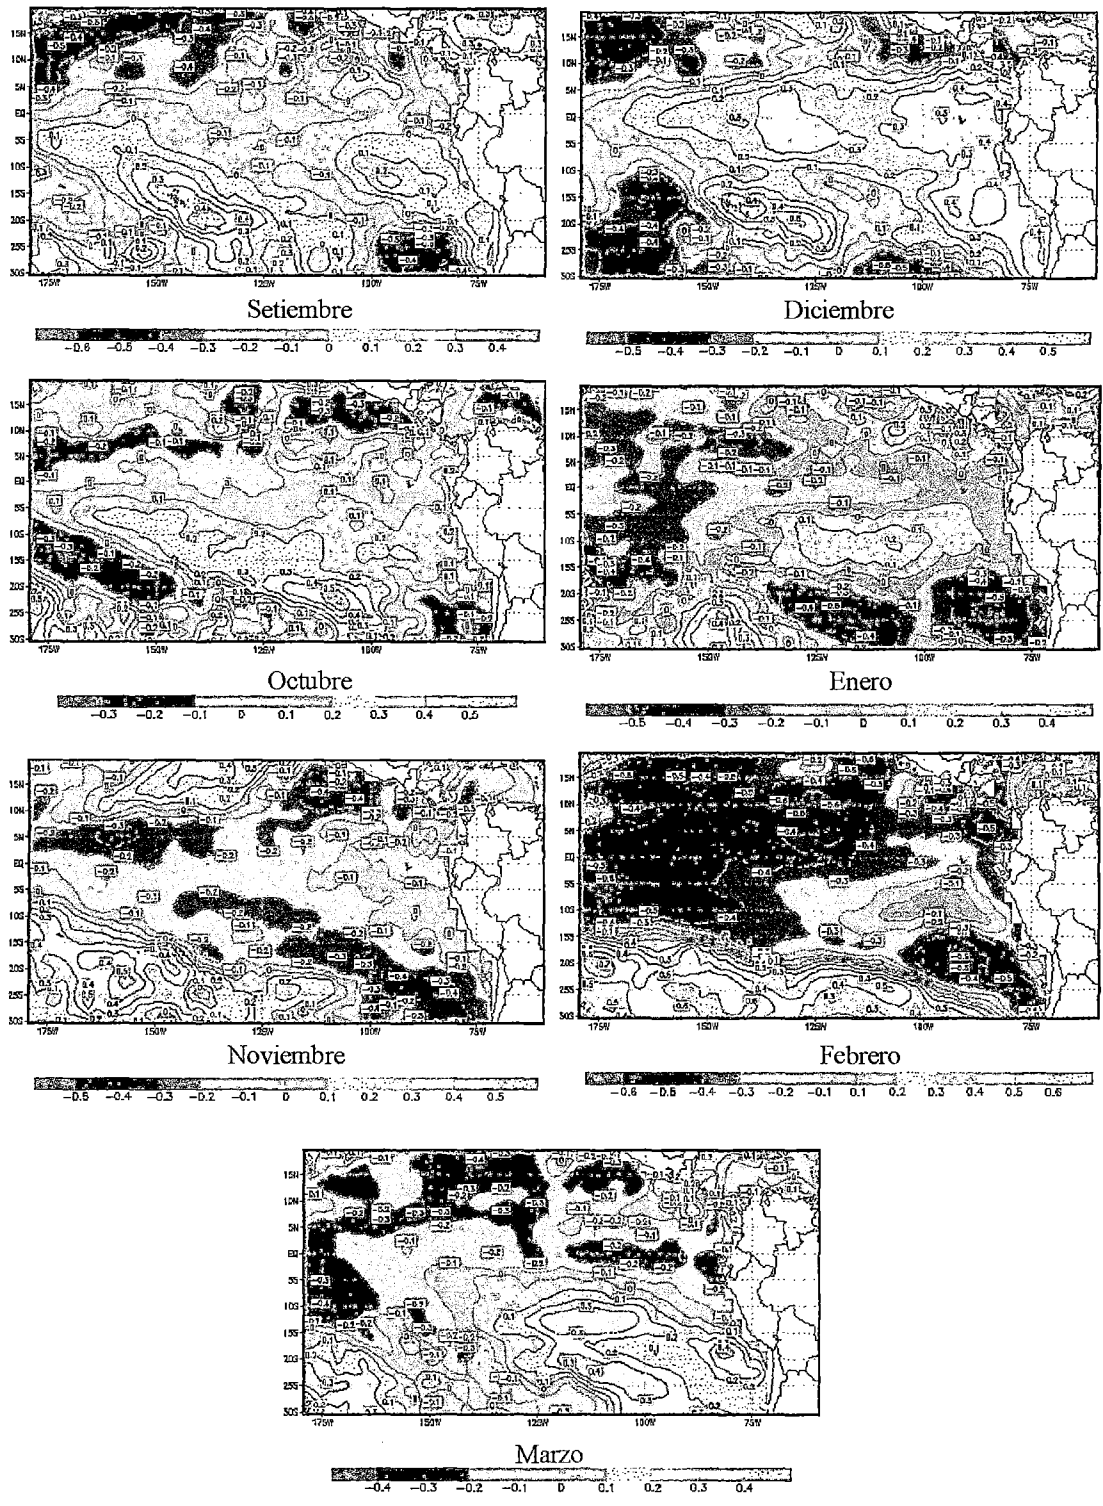


Figura 11. Mapas de correlación. TSM vs Precipitación. Estación-Usnio obtenidos durante el proceso de calibración.

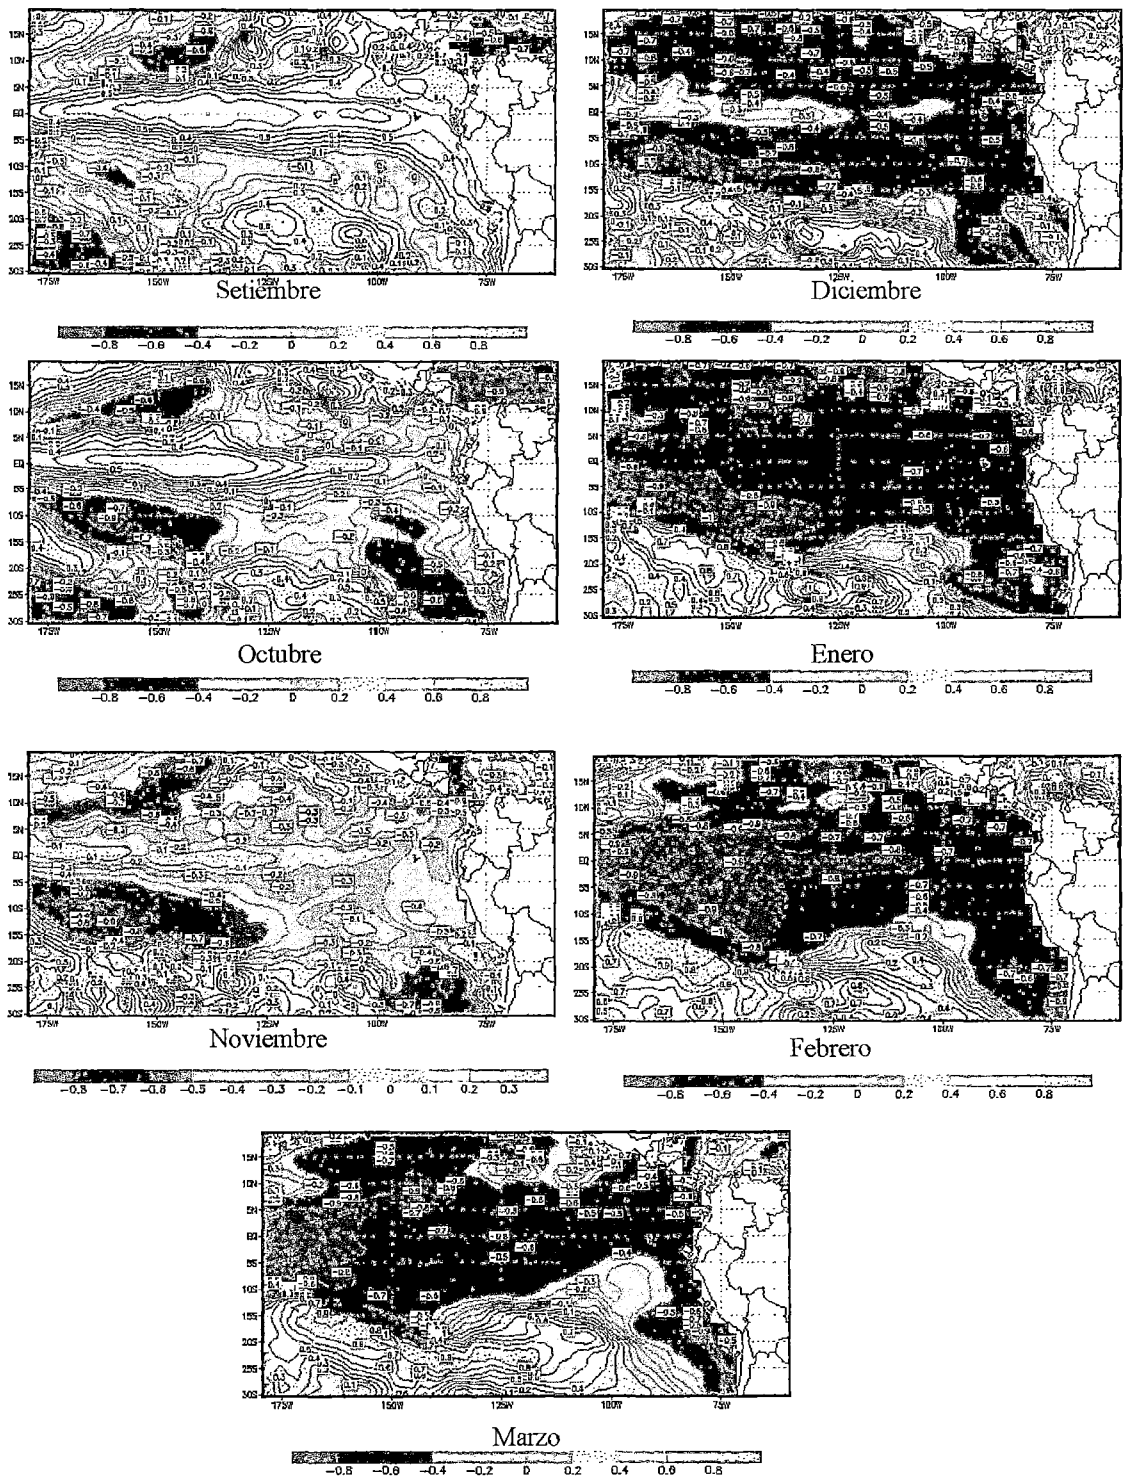


Figura 12. Mapas de correlación. TSM vs Temp. máxima. Estación-La Toma obtenidos durante el proceso de calibración.

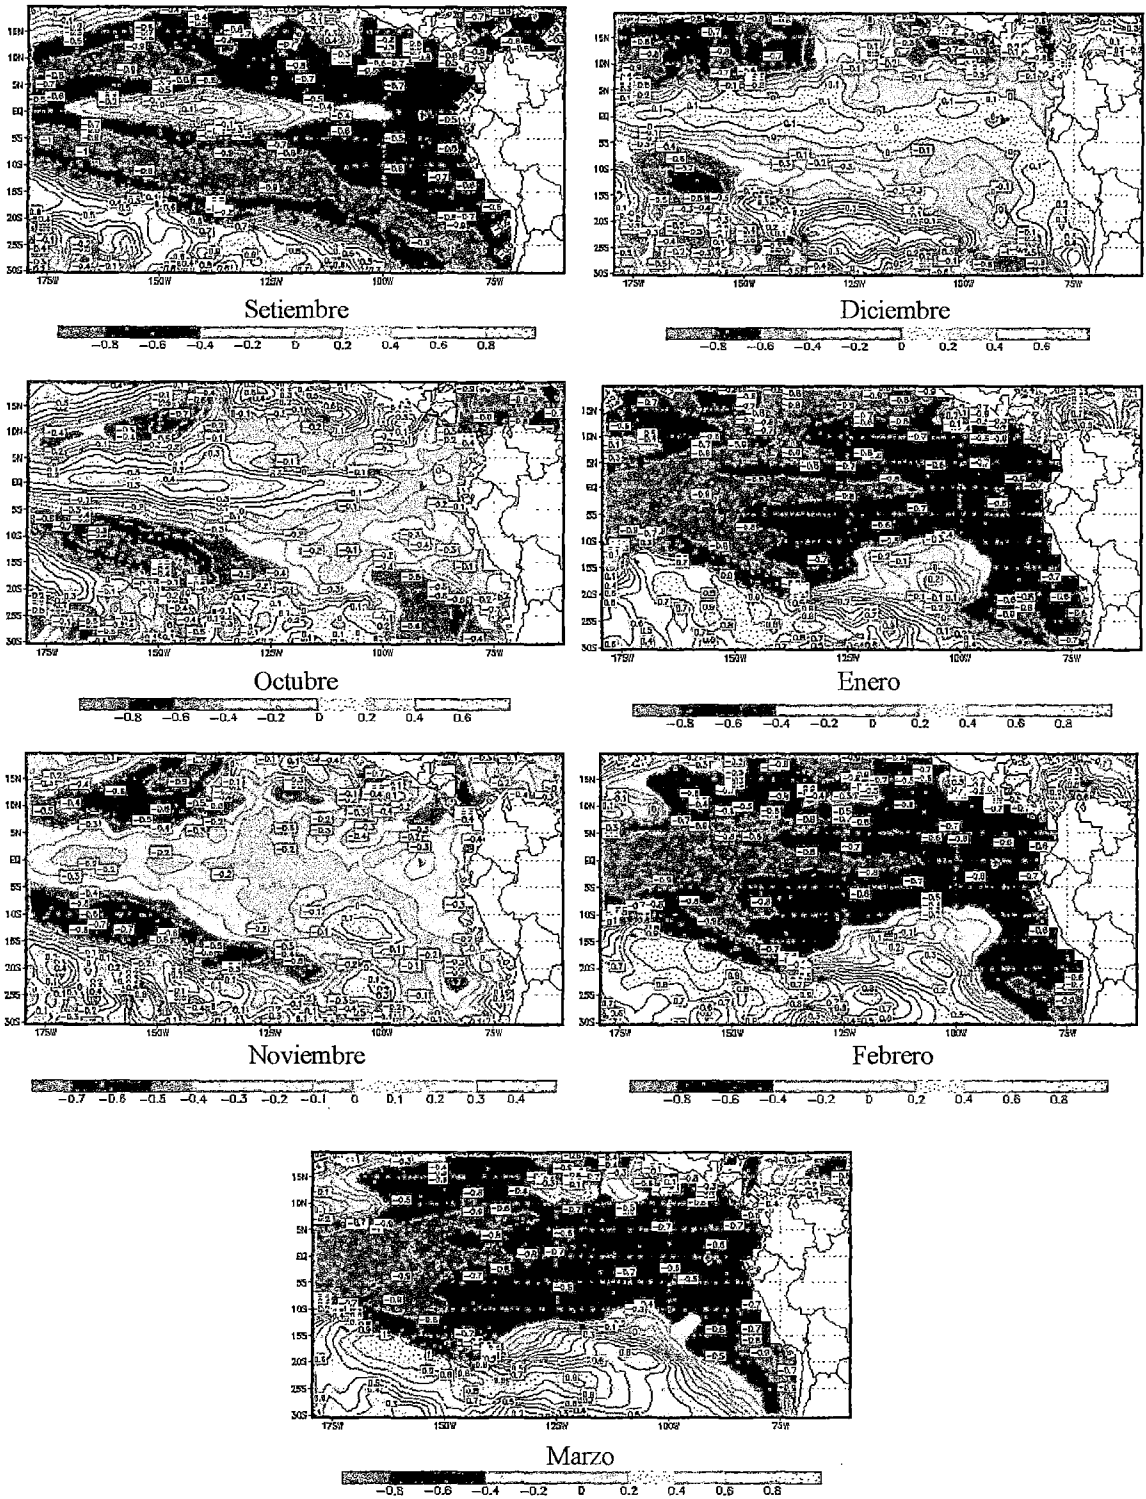


Figura 13. Mapas de correlación. TSM vs temperatura mínima. Estación-La Toma obtenidos durante el proceso de calibración.

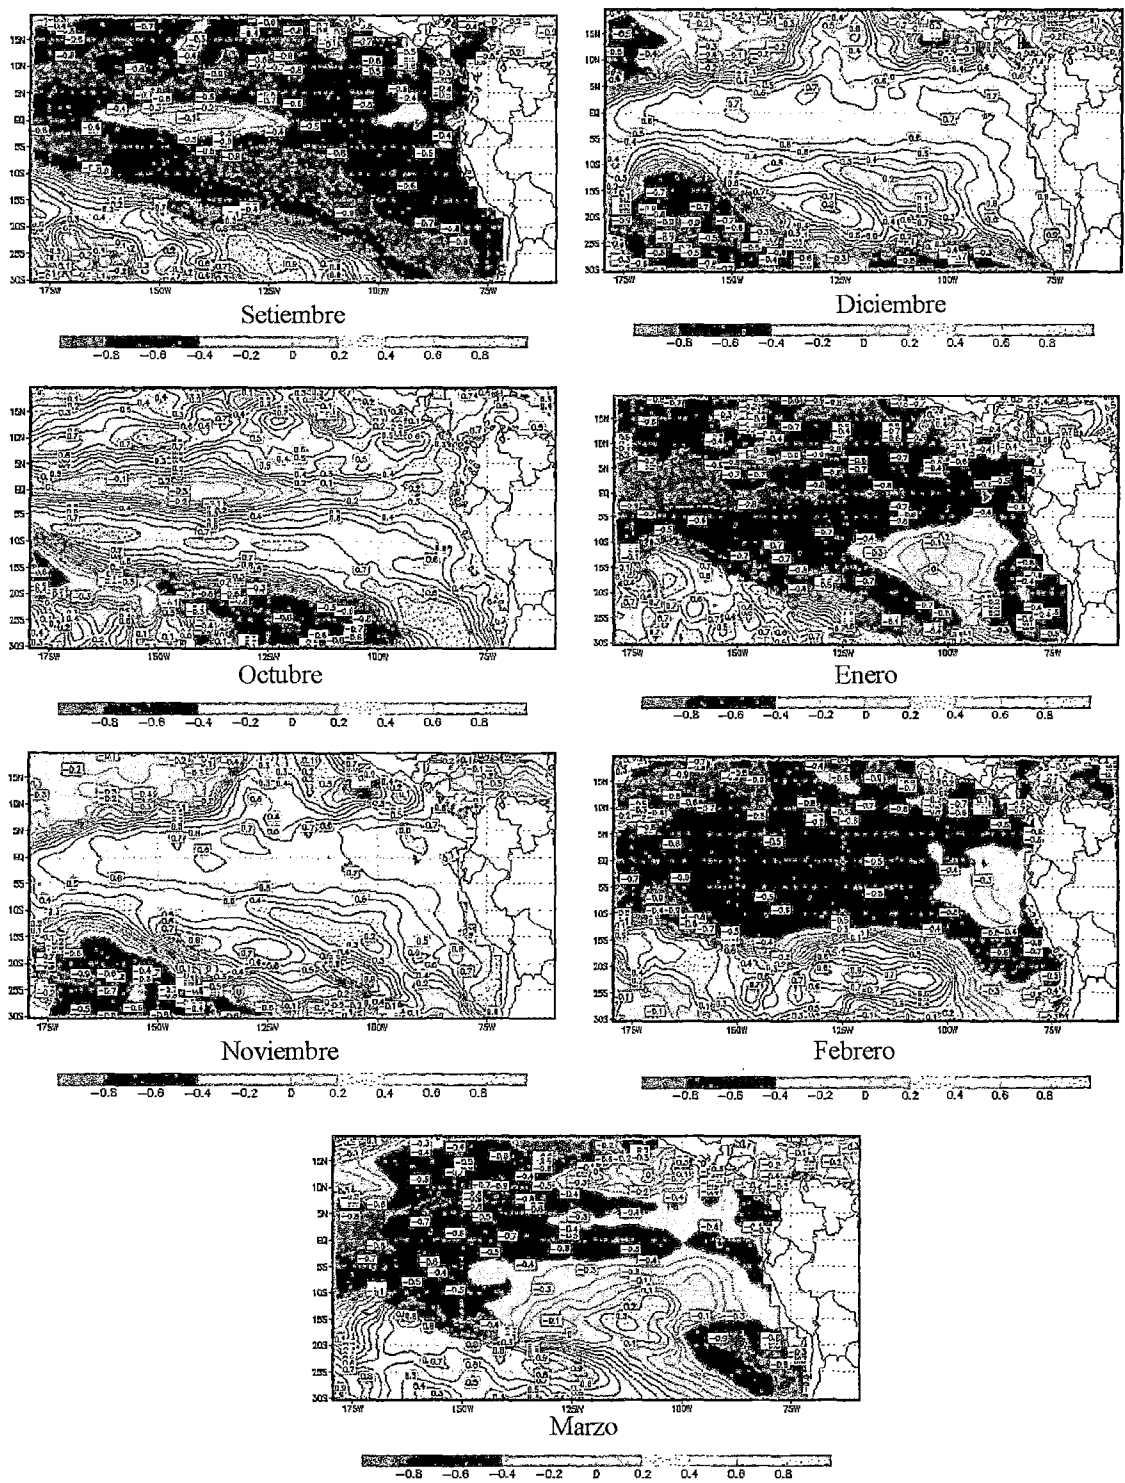


Figura 14. Mapas de correlación. TSM vs Precipitación. Estación-La Toma obtenidos durante el proceso de calibración.

4.2 Validación y comparación

Una vez observado el grado de respuesta entre la TSM y la variabilidad climática estacional se construyeron las ecuaciones de regresión múltiple para cada variable meteorológica y así se estimaron temperatura y precipitación, las mismas que fueron comparados con datos observados correspondientes al mismo período.

En este proceso se utilizaron las ecuaciones de pronóstico que se muestran en el Anexo 4. Los datos generados aquí fueron comparados con los datos observados correspondientes a un mismo período, para las estaciones de La Toma y Manzana 1999-00, y un mayor período para Usnio de 1998-2000. En la Figura 15, se muestra la distribución temporal de los datos estimados y observados para cada variable y estación meteorológica, esto fue obtenido con el 33% de datos restante. Si bien es cierto que en la distribución de la serie temporal se puede observar que los datos estimados y observados no obedecen a un comportamiento homogéneo, pues la mejor manera de evaluar este comportamiento es mediante los coeficientes de correlación tal como se muestra en la Figura 16.

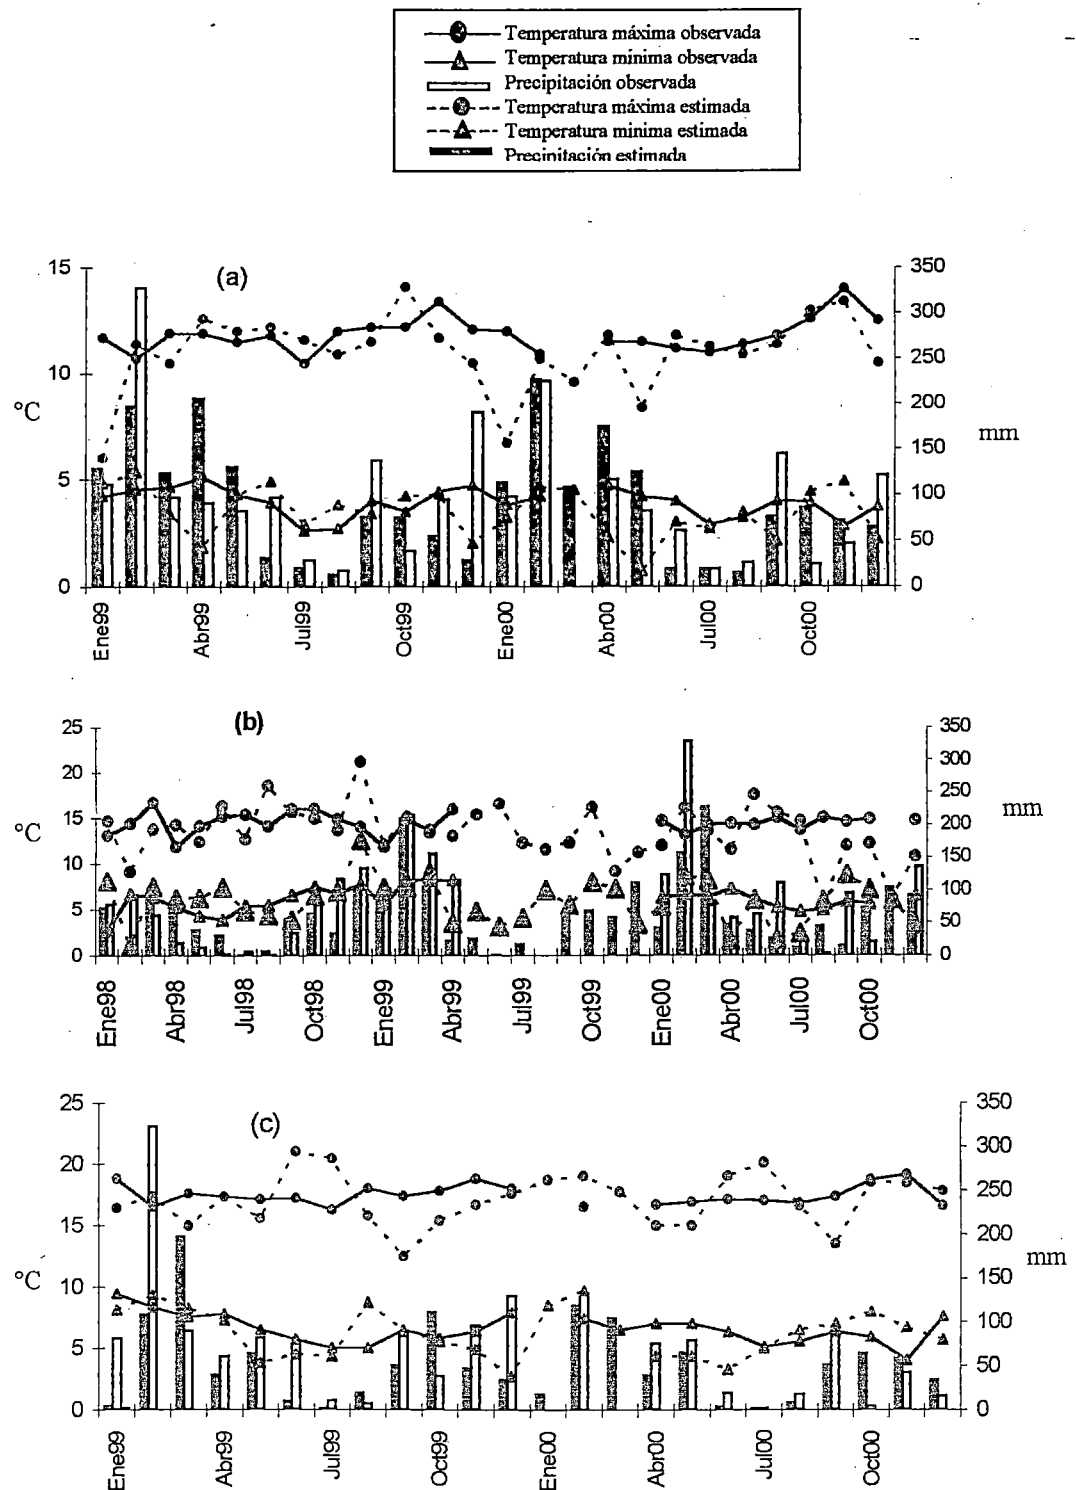
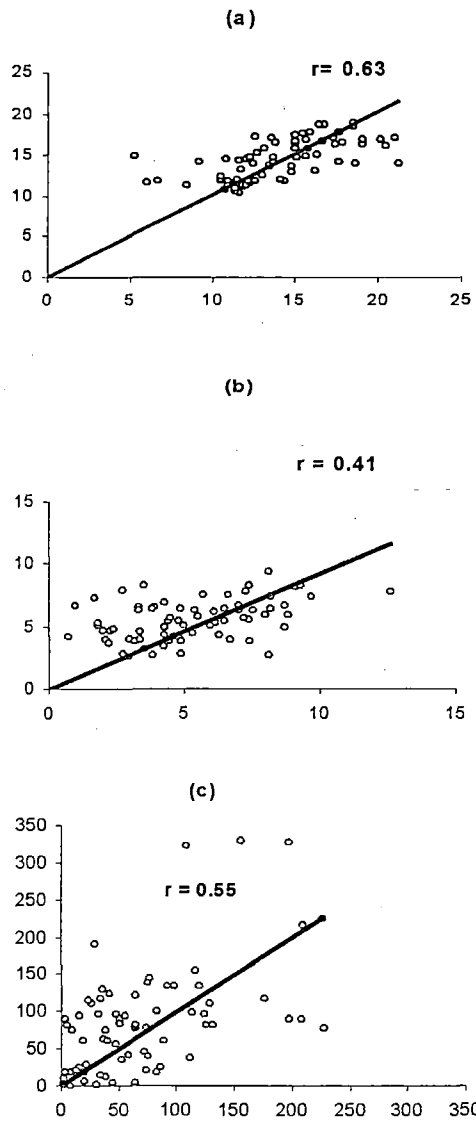


Figura 15. Distribución temporal de datos de variables meteorológicas estimado vs observado durante el proceso de validación para las estaciones de La Toma (a), Usnio (b) y Manzanas (c).

Debido a la poca información disponible para la comparación, los coeficientes de correlación tuvieron que ser obtenidos de manera general para cada variable meteorológica, buscando mostrar una mayor capacidad de estimación al considerar amplios rangos de condiciones que son proporcionados por la ubicación de cada estación meteorológica. En la Figura 16 se muestran las curvas estimado vs observado, donde los valores obtenidos de 0.63, 0.41 y 0.55 para el coeficiente de correlación corresponden a las variables: temperatura máxima, mínima y precipitación respectivamente, indicando esto que el modelo explica el 63%, 41% y 55% de la variación de cada una de estas variables meteorológicas. El porcentaje restante es explicado mediante el análisis de residuales.

Una amplia dispersión entre los datos estimados y observados para las tres variables meteorológicas se observan la Figura 17. Los análisis de residuales sugieren que el desarrollo de los modelos de regresión múltiple son muy apropiados para años normales. Esto se observó con mayor detalle en el análisis de residuales de terciles desarrollado para la estación Usnio durante el proceso de validación por contar con un mayor registro de observación. Así, para la variable temperatura máxima (fig. 18a y 18b), los residuales positivos pertenecen a años con presencia del Fenómeno del Niño, que es interpretado por el modelo como una sobrestimación de la temperatura máxima. Mientras que durante la presencia del Fenómeno de La Niña se presenta una subestimación de esta variable. En el caso de la temperatura mínima (Figura 18c y 18d), los terciles probabilísticos muestran que los residuales están bien distribuidos durante los años afectados por El Niño, sin embargo, durante los años en que se presenta el evento La Niña, los terciles probabilísticos de residuales demuestran un gran ruido en los valores estimados. Para la variable precipitación (Figura 18e y 18f), los resultados muestran que durante años afectados por El Niño los modelos de regresión múltiple producen gran ruido. Esto influye en la dispersión que se observa en los residuales obtenidos (Figura 17).

E
S
T
I
M
A
D
O



O B S E R V A D O

Figura 16. Correlaciones de datos observados versus estimados para temperatura máxima (a), temperatura mínima (b) y precipitación (c) para la cuenca La Encañada-Tambomayo




Figura 17. Residuales de datos observados versus estimados de temperatura máxima (a), temperatura mínima (b) y precipitación (c) para la cuenca La Encañada-Tambomayo

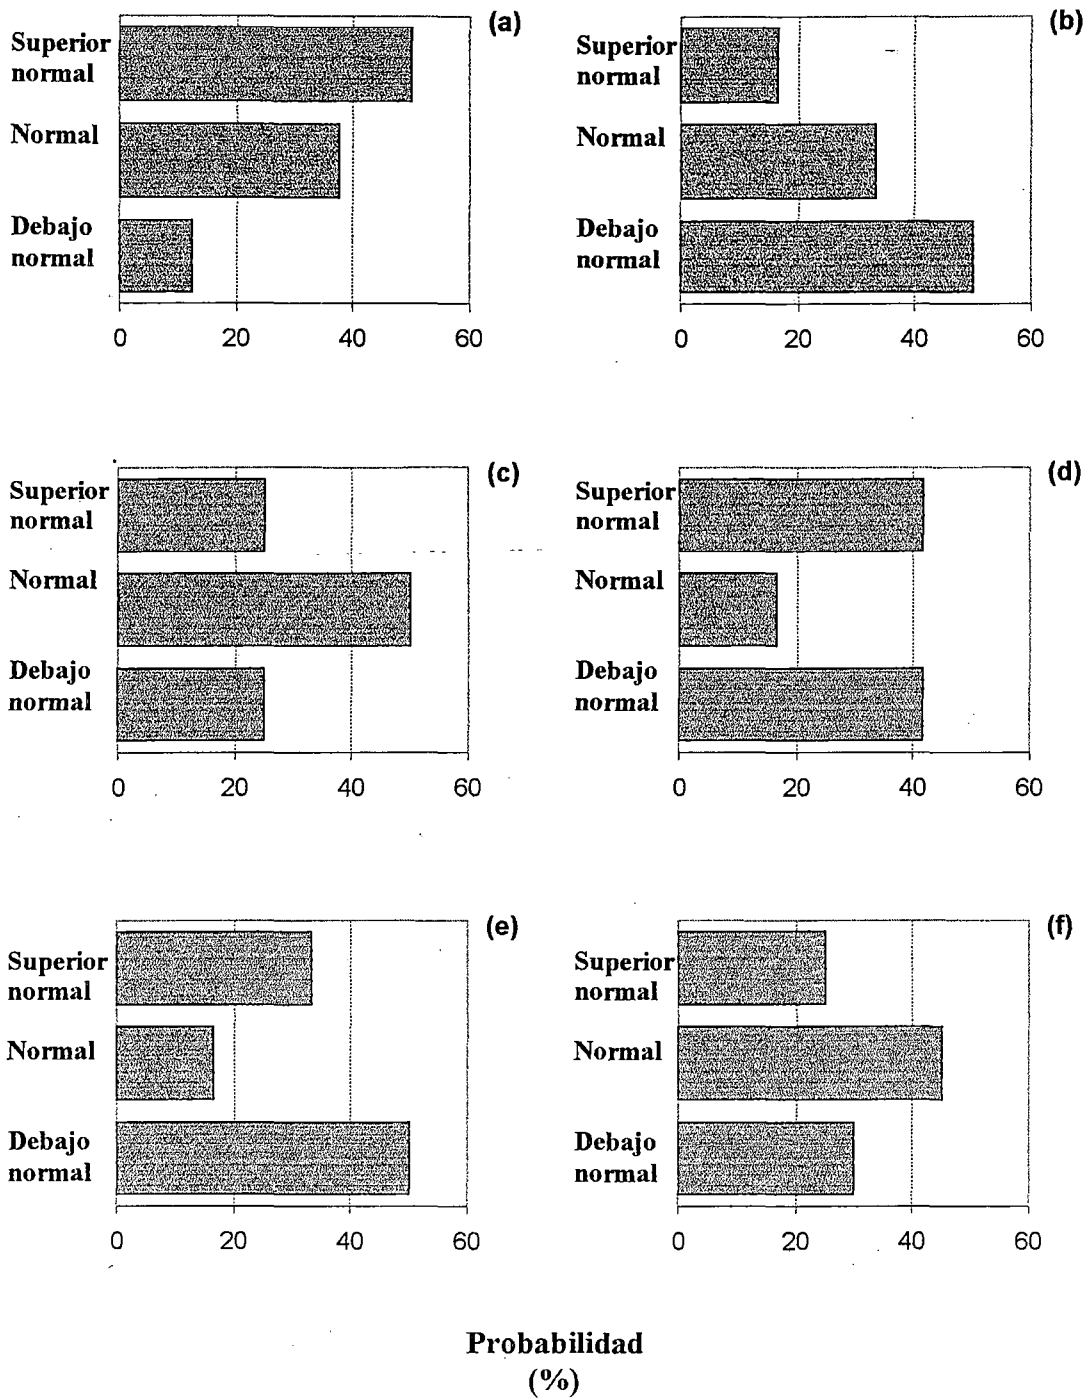


Figura 18. Tercil probabilístico de residuales en la Estación Usnio para eventos de El Niño (a, c y e) y La Niña (b, d y f). Variables meteorológicas correspondientes (a) y (b) para temperatura máxima, (c) y (d) temperatura mínima y (e) y (f) precipitación.

4.3 Aplicación

Después de realizar la validación de las ecuaciones encontradas y la respectiva comparación de los datos estimados se logró realizar un pronóstico entre septiembre del 2003 y marzo 2004. Esto constituye el primer paso en responder al segundo objetivo sobre la aplicación de los pronósticos para una campaña agrícola en la zona de estudio. En el Cuadro 2 se muestran los resultados del pronóstico probabilístico correspondiente al período comprendido entre los meses de septiembre del año 2003 a marzo del 2004, donde de acuerdo al modelo de regresión múltiple utilizado, la temperatura máxima, temperatura mínima así como la precipitación fueron muy similares a los datos climáticos mensuales en la cuenca Encañada - Tambomayo. Lamentablemente, no fue posible hacer la comparación con datos registrados para el período de pronóstico, ya que por problemas de mantenimiento no se tienen datos completos para dicho período de análisis. Sin embargo, cabe mencionar que el pronóstico obtenido en este trabajo de investigación fue también confirmado por el pronóstico climático realizado en diciembre del 2003 por el International Research Institute for Climate Prediction (IRI, 2003). Los resultados del cuadro 1 con respecto al pronóstico fueron utilizados por los modelos de simulación tal como se detalla en la metodología para llegar hasta los mapas de fechas óptimas de siembra para el cultivo de papa respondiendo así al segundo objetivo planteado. El tercer objetivo es analizado en el punto 5.4.

Cuadro 2. Datos climáticos mensuales versus datos pronosticados de temperatura máxima, mínima y precipitación de cada estación meteorológica para el período de setiembre del 2003 a marzo del 2004.

Mes	<u>Temperatura Máxima</u>		<u>Temperatura Mínima</u>		<u>Precipitación</u>	
	Climático	Pronóstico	Climático	Pronóstico	Climático	Pronóstico
La Toma						
Setiembre	12.0	12.0	3.1	3.0	68.6	88.8
Octubre	12.3	11.8	3.6	3.2	45.7	45.2
Noviembre	11.9	11.3	3.1	3.0	69.4	68.6
Diciembre	10.8	10.8	3.1	2.7	128.7	132.3
Enero	10.7	10.6	2.7	2.4	92.7	88.2
Febrero	10.4	11.3	3.9	2.0	143.1	103.2
Marzo	9.8	12.0	2.5	1.6	102.5	199.1
Usnio						
Setiembre	14.7	15.0	6.3	6.4	40.0	39.3
Octubre	14.9	14.5	6.7	6.4	62.6	65.3
Noviembre	14.7	14.7	6.1	6.1	67.4	65.4
Diciembre	14.2	14.5	6.4	6.6	75.0	68.6
Enero	14.5	14.7	5.9	5.7	92.8	94.9
Febrero	14.2	14.5	6.9	5.7	108.0	110.3
Marzo	14.0	13.4	6.5	5.8	105.3	86.9
Manzanas						
Setiembre	16.7	15.6	5.8	3.7	53.9	65.4
Octubre	17.5	16.0	6.4	4.8	45.1	51.0
Noviembre	17.9	16.7	5.6	5.8	63.2	62.7
Diciembre	17.0	16.6	7.3	6.5	52.9	64.3
Enero	16.2	17.5	6.5	6.3	63.4	85.2
Febrero	15.9	17.1	6.9	7.6	147.7	147.4
Marzo	16.1	16.1	6.6	6.5	105.5	106.7

4.4 Evaluación del pronóstico de producción

La Figura 19 muestra los mapas de fechas óptimas de siembra que son el resultado de la desagregación espacial y temporal de datos de clima y de información de temperatura superficial de agua de mar (TSM). Estos mapas han sido generados a partir de la información de pronóstico de la variabilidad climática estacional para el período comprendido entre septiembre del 2003 y marzo del 2004 obtenida en los acápite anteriores.

Estos mapas indican que los más altos rendimientos se presentan en los meses simulados, siendo las Figuras 19a y 19b los mapas de producción óptima con alta y baja fertilización nitrogenada respectivamente. Sánchez (2004) elaboró mapas de distribución de siembra para diferentes cultivos de la cuenca La Encañada-Tambomayo, donde se observa que la campaña de siembra más grande para el cultivo de papa corresponde al mes de junio. Además señala que los agricultores tienden a adoptar una política de minimización del riesgo, sembrando, en algunos casos durante todo el año pequeñas cantidades, con el objetivo de evitar pérdidas y garantizar la despensa de alimentos, ya que gran parte de las familias campesinas viven en condiciones de subsistencia, donde la mayor parte de la producción es destinada al autoconsumo. No obstante ellos buscan la comercialización de sus excedentes, ya que el mercado constituye el único camino por el cual consiguen bienes necesarios para el consumo familiar, como kerosene, azúcar, sal, ropa y útiles escolares entre otros. Es así que el mercado tiene mucha importancia y producir antes de fecha resulta rentable, ya que vender un producto depende de la época de cosecha. Esta situación justificaría porque el mayor período de siembra corresponde al mes de junio, tratándose de época seca en vez de hacerlo en época húmeda, donde es posible conseguir mayor producción. Algunos reportes indican valores de 6 tn/ha a menos sembrando en junio y comparando con los mapas de fechas óptimas de siembra se observa que los rendimientos entre 5 y 10 tn/ha son posibles dentro de los meses simulados. Sin embargo hay que considerar que las mejores producciones no necesariamente van asociados a los mejores ingresos. Esto va depender de la época de cosecha, de la opción de almacenar el producto y de la presión económica de la familia para conseguir dinero. Es así que los campesinos están forzados a vender sus excedentes de producción a corto plazo por falta de recursos

económicos. Pero en una economía de subsistencia donde la prioridad es garantizar la seguridad alimentaria, los mapas de fechas óptimas de siembra muestran una alternativa estratégica en la toma de decisiones considerando la reducción a la vulnerabilidad climática, siendo este el factor predominante en la producción de sus cultivos. Además de brindar la opción de seleccionar el mes de siembra que resulte más conveniente para ellos con respecto a la época en que desean cosechar y tal vez permitirles la comercialización de sus excedentes. Entonces, comparando los mapas de producción bajo condiciones óptimas de siembra con el mapa de distribución de siembra de papa (Figura 20) se observa que las siembras no se realizaron en las fechas óptimas, lo cual estaría influyendo en el nivel de ingresos de los agricultores. Así que el uso de los mapas de fechas óptimas de siembra es para traducir su información en dar soporte a las tomas de decisiones y no para hacer una decisión real. Estos resultados demuestran que los agricultores en los Andes no cuentan con una herramienta confiable para el pronóstico que le permita la optimización de la producción y solamente adoptan una política de minimización de riesgos a pesar de utilizar sus conocimientos tradicionales (Sánchez, 2004). Por otro lado, los pronósticos de la variabilidad climática estacional están disponibles por el Servicio Nacional de Meteorología e Hidrología, pero existe una brecha importante entre la información proporcionada y la requerida por las poblaciones rurales. El beneficio de los pronósticos se incrementa cuando sus resultados son utilizados para tomar decisiones que reduzcan la vulnerabilidad de impactos negativos de la variabilidad climática (Hanson, 2002). Estas decisiones relacionadas con los sistemas de producción agrícola y efectos adversos de la variabilidad climática no solo dependen de la parte afectada, que son los agricultores de las poblaciones rurales, sino que involucra diversos sectores comprometidos a trabajar y garantizar una mejor calidad de vida a las poblaciones rurales. Este tipo de metodología representa un aporte importante como herramienta de previsión por su utilidad en la reducción de la vulnerabilidad ambiental y soporte a los tomadores de decisiones. Pero claro está que este tipo de estrategia requiere necesariamente de un suministro constante de información, así como un compromiso de instituciones profundamente involucradas en el tema, de tal manera de generar un sistema de alerta temprana en beneficio de poblaciones rurales. Actualmente existe un gran esfuerzo en desarrollar métodos más dinámicos que involucren procesos físicos y que puedan representar mejor el comportamiento meteorológico de un

área determinada. Bajo este contexto el desarrollo de una metodología es el primer paso en lograr la integración de un sistema de gestión de cuenca. Los resultados obtenidos en este trabajo están basados en un aprovechamiento empírico de modelos de regresión múltiple que muestran la necesidad de profundizar en el análisis. Por lo tanto, es necesario profundizar en este tipo de metodología por sus múltiples aplicaciones en diversas áreas de estudio tales como clima, ecología, hidrología, y ciencias del suelo donde ha sido ampliamente estudiada. Desde que información espacial en baja resolución este disponible tanto técnicas empíricas como dinámicas pueden ser utilizadas como alternativa para obtener datos en una resolución adecuada.

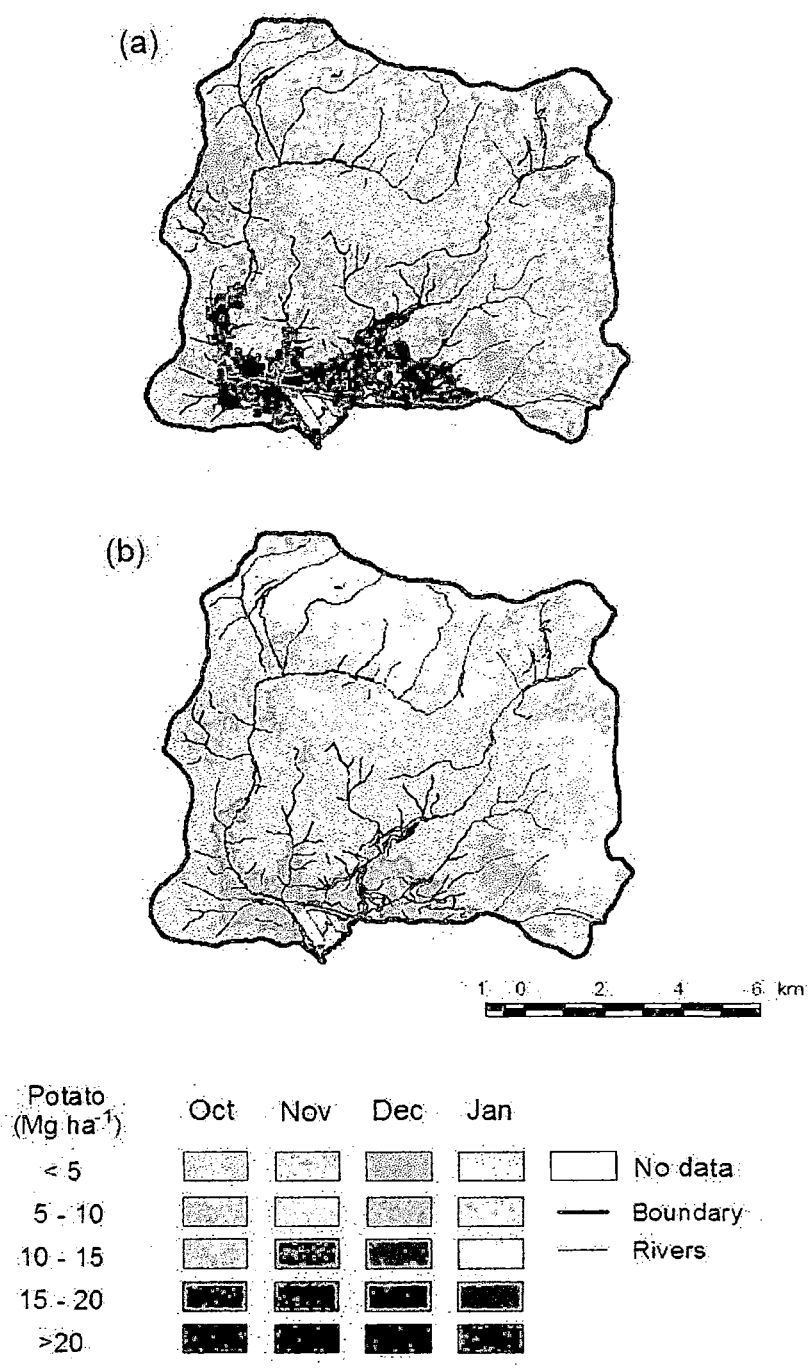
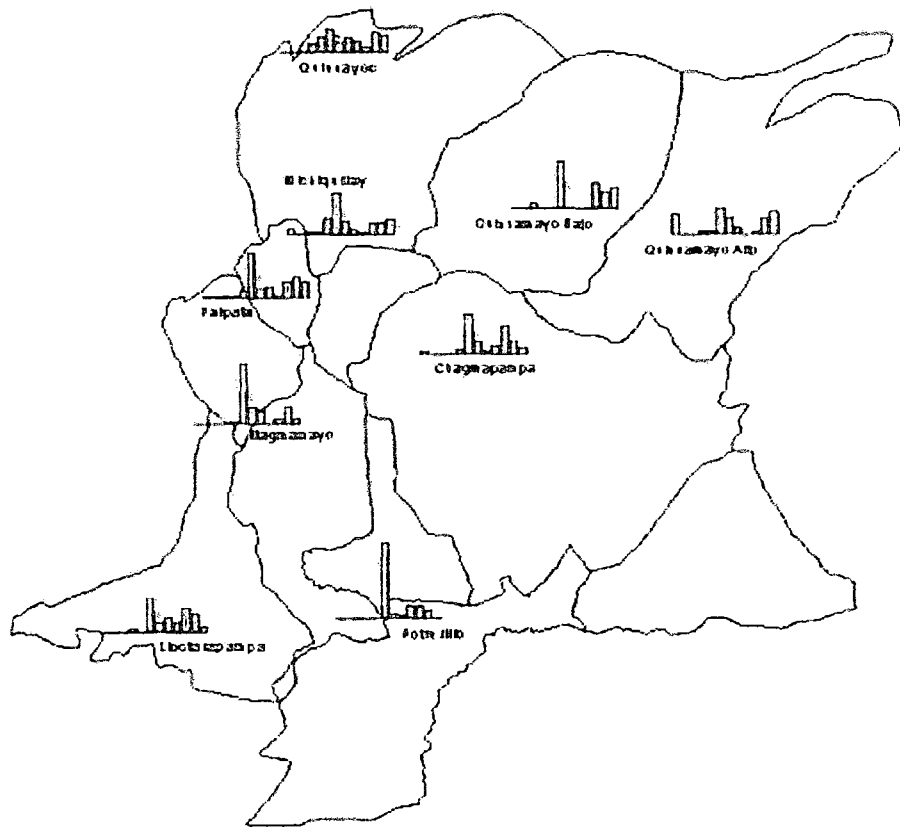


Figura 19. Mapas de fechas óptimas de siembra para el cultivo de papa sobre alta (a) y baja (b) fertilización



Fuente: Sánchez, 2004

Figura 20. Mapa de distribución de siembra del cultivo de papa para la cuenca La Encañada - Tambomayo

V. CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

El grado de respuesta entre la temperatura superficial de agua de mar y la variabilidad climática estacional encontrado en este trabajo de investigación para la cuenca La Encañada – Tambomayo permitió construir ecuaciones de pronóstico y así predecir precipitación y temperatura del aire, las mismas que integradas con herramientas de simulación se tradujeron en mapas de fechas óptimas de siembra para el período de octubre del 2003 y enero del 2004.

Mediante el uso de técnicas de regresión múltiple y desagregación espacial y temporal de la información proporcionada por los Modelos de Circulación Global (MCG) se encontró que es posible emplear la información de pronóstico de datos de temperatura de agua de mar para realizar pronósticos de la variabilidad climática estacional.

Asimismo, queda demostrada la capacidad de los modelos de regresión múltiple para predecir la variabilidad climática estacional en la zona de los Andes Peruanos, desarrollándose un caso para la cuenca La Encañada-Tambomayo, donde los modelos de regresión múltiple explicaron el 63, 41 y 55% de la variación para temperatura máxima, mínima y precipitación respectivamente. Los modelos de regresión múltiple resultaron bastante apropiados para años normales, mientras que el análisis de residuales sugirió generar nuevas ecuaciones para años con presencia del Fenómeno de El Niño o de La Niña.

El pronóstico desarrollado para el periodo comprendido entre septiembre del 2003 y marzo del 2004 indicó condiciones normales, el mismo que fue confirmado por el pronóstico climático realizado en diciembre del 2003 por el International Reserarch Institute for Climate Prediction (IRI, 2003).

El pronóstico en mapas de fechas óptimas de siembra representa el uso potencial de los pronósticos climáticos estacionales, ya que a pesar que estos pronósticos están disponibles por el Servicio Nacional de Meteorología e Hidrología, esta situación no provoca un cambio en las decisiones agrícolas justamente por tratarse de información poco entendible a sus necesidades.

El pronóstico climático, así como el pronóstico climático estacional son principalmente útiles si es direccionado a una necesidad real y entonces opciones de decisiones viables pueden ser adoptadas por los tomadores de decisiones (Hansen, 2002). Cabe señalar que el verdadero uso de los mapas de fechas óptimas de siembra es dar soporte en la toma de decisión y no para hacer decisiones reales, ya que no necesariamente los mejores rendimientos indican mejores ingresos esto depende de algunos factores tales como el tipo de cultivo, cercanía al mercado, fechas de cosecha, etc.

A pesar que la mayor campaña de siembra ha sido registrada en el mes de junio (Sánchez, 2005) reportándose valores de producción menores a 5 ton/ha para la zona de estudio (Tapia, 1995), los modelos de simulación con la metodología desarrollada en este trabajo han demostrado que valores entre 5 y 10 ton/ha son posibles de obtener dependiendo de las fechas de siembra, las mismas que podrían incrementarse con el empleo de fertilizantes.

El desarrollo de la metodología se constituye en una herramienta potencial en la toma de decisiones estratégicas que buscan una mejor calidad de vida en zonas de bajos recursos como los Andes Peruanos, enfocándose a través de la reducción del riesgo a la vulnerabilidad climática, ya que este es el principal factor que condiciona el ingreso económico de estas zonas.

El Modelo desarrollado en el presente trabajo de investigación puede ser replicado a cualquier otra zona de estudio siempre y cuando se encuentre la explicación física entre la TSM y variabilidad climática, además de otros ajustes necesarios a la información geográfica.

5.2 Recomendaciones

La falta de información meteorológica en zonas altoandinas limita un mejor entendimiento de la variabilidad climática estacional por lo cual se debe promover la instalación y equipamiento de estaciones meteorológicas así como el mantenimiento de las mismas.

La información de TSM proporcionada por los MCG debe resultar en una resolución más fina ya que por mas técnicas de desagregación simples o complejas que se realicen estas arrastran cierto grado de error. Así que la instalación de boyas para el registro de TSM en puntos menos espaciados también debe impulsarse ya que esta demostrada su influencia en la variabilidad climática estacional.

El modelo de simulación utilizado necesita ser perfeccionado ya que solo considera escenarios de monocultivo, lo cual no es real, puesto que los sistemas agrícolas altoandinos se caracterizan por poseer una diversidad de cultivos. Sin embargo, esta es una primera aproximación que muestra la posibilidad de análisis de las interacciones entre los sistemas naturales y antropicos utilizando herramientas modernas.

Es necesario desarrollar estudios más profundo que permitan un mayor entendimiento del comportamiento meteorológico en el área de estudio y determinar los estimadores mas apropiados que permitan predecir con suficiente anticipación efectos adversos del clima y así reducir la vulnerabilidad al riesgo en zonas de los Andes Peruanos.

En trabajos posteriores con metodología similar a la desarrollada debe realizarse un monitoreo de sus resultados en campo de tal manera de evaluar la confiabilidad de la metodología y/o permitan realizar ajustes en la misma y lograr un impacto positivo en zonas altoandinas.

VI. BIBLIOGRAFIA

Baigorria, G.A., Romero, C.C., Olivares, M., 2002. La Encañada and Tambomayo Watersheds, Cajamarca, Peru. *In*: [CD-ROM]: Disk 7 of 9. Himalayan Andean Collaborative Watersheds Projects. CIP – IDRC – CRDI. BC, Canada.

Baigorria, G.A., Villegas, E.B., Trebejo, I., Carlos, J.F., Quiroz, R., 2004. Atmospheric transmissivity: distribution and estimation around Central Andes. Submitted to *International Journal of Climatology*.

Baigorria, G. A., 2005. Climate Interpolation for Land Resource and Land Use Studies in Mountainous regions. PhD dissertation. Wageningen University. The Netherlands. 168 pp.

Boelens R., Dávila, G., 1998. Buscando la equidad. Servicio Holandés de Cooperación al Desarrollo-SNV.

Bristow, K., Campbell, G., 1984. On the relationship between incoming solar radiation and daily maximum and minimum temperature. *Agricultural and Forest Meteorology* 31, 159-166.

De la Cruz, J., Zorogastúa, P., Hijmans, R.J., 1999. Atlas Digital de los Recursos Naturales de Cajamarca. Departamento de Sistemas de Producción y Manejo de Recursos Naturales. Documento de Trabajo No. 2. CIP – CONDESAN. Lima, Peru.

Gilford, M.T., Vojtesak, M.J., Myles, G., Bonam, R.C., Martens, D.L., 1992. South America - South of the Amazon River: A Climatological Study. USAF Environmental Technical Applications Center (USAFETAC/TN—92/004). Scott Air Force Base, IL.

Hansen, J.W., 2002. Realizing the potential benefits of climate prediction to agriculture: issues, approaches, challenges. *Agricultural Systems* 74, 309-330.

Isaaks, E.H., Srivastava, R.M., 1989. An Introduction to Applied Geostatistics. Oxford University Press. NY.

Jones, J.W., Tsuji, G., Hoogenboom, G., Hunt, L.A., Thornton, P.K., Wilkens, P.W., Imamura, D.T., Bowen, W.T., Singh, U., 1998. Decision support system for agrotechnology

transfer: DSSAT v3. p. 157-177. *In* Tsuji, G.Y., Hoogenboom, G., Thornton, P.K. (ed.) *Understanding Options for Agricultural Production*. Kluwer Academic Publishers, Dordrecht, The Netherlands.

Romero, C.C., 2004. Rainfall characterization in La Encañada. *In* A multi-scale approach for erosion impact assessment in the Andes. PhD dissertation. Wageningen University. Wageningen, the Netherlands.

Romero, C.C., Stroosnijder, L., 2001. A multi-scale approach for erosion impact assessment in the Andes. *In* Proceedings of the Third International Symposium on Systems Approaches for Agricultural Development [CD-ROM computer file]. CIP, Lima, Peru.

Sánchez, María L. 2004. Modelamiento geoespacial para el análisis de la vulnerabilidad ambiental, bajo diferentes escenarios de manejo agrícola. Lima-Perú.

Solman, S., Nuñez, M. 1999. Local Estimate of Global Climate Change: A Statistical Downscaling Approach, *International Journal of Climatology*, 19: 835-861

Storch, H., Zwiers, F. 1999. *Statistical Analysis in Climate Research*. Cambridge University Press, United Kingdom, 488 pp.

Tanco, Raul A. 2000. *Climlab 2000 - Manual*. International Research Institute for climate prediction - IRI. 65 p.

Tapia, M., 1995. *La Encañada, Caminos Hacia la Sostenibilidad*. ASPADERUC, CONDESAN-CIP, Fondo Perú-Canadá. Proyecto PIDAE. Lima, Perú.

Trueba, C., Gutiérrez, J., Cofiño, A., Rodríguez M. 2000. Redes Neuronales y Patrones de Analogía Aplicados al Downscaling en Modelos Climáticos, *Instituto Nacional de Meteorología, España*, 113-121

USDA-NRCS, 1998. *Keys to Soil Taxonomy*. Eighth edition. Soil Survey Staff.

Valdivia, R.O., 2002. The economics of terraces in the Peruvian Andes: An application of sensitivity analysis in an integrated assessment model. M.S. thesis. Montana State University – Bozeman, Montana, MT.

Overmars, K.P., 1999. Developing a method for downscaling soil information from regional to catena Level. M.S. thesis. Wageningen Agric. Univ., Wageningen, The Netherlands.

Richardson, C.W., Wright, D.A., 1984. WGEN: a model for generating daily weather variables. USDA, Agric. Res. Service, ARS-8, 83 pp.

Ritchie, J.T., Griffin, T.S., Johnson, B.S., 1995. SUBSTOR: functional model of potato growth, development and yield. p. 401-435. *In* Kabat, P., Marshall, B., van den Broek, B.J., Vos, A., van keulen, H. (ed.) Modelling and parametrization of the soil-plant-atmosphere system. Wageningen Pers, Wageningen, The Netherlands.

Anexo 1. Relación de años afectados por los fenómenos de El Niño y La Niña utilizado en los terciles probabilístico de residuales durante el proceso de validación para la estación Usnio.

El Niño	Año	La Niña	Año
1	1951	1	1950-51
2	1953	2	1954-56
3	1957-58	3	1964-65
4	1963-64	4	1967-68
5	1965-66	5	1970-72
6	1968-70	6	1973-76
7	1972-73	7	1984-85
8	1976-77	8	1988-89
9	1977-78	9	1995-96
10	1982-83	10	1998-2000
11	1986-88	11	2000-01
12	1990-92		
13	1993		
14	1994-95		
15	1997-98		

Fuente: IRI - 2002

Anexo 2. Resumen del reporte estadístico de las ecuaciones de pronóstico y georeferenciación de cada área del Océano Pacífico considerado para la estación La Toma

Precipitación (Pp)	R ²	F value	ECM	TSM ₁				TSM ₂				TSM ₃				TSM ₄			
				LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y
Ene	0.81	8.82	27.44					-180	-150	5	-4								
Feb	0.95	443.84	3.95					-140	-120	-20	-25								
Mar	0.83	32.08	27.61					-95	-75	-17	-25								
Set	0.78	10.03	2.76									-115	-85	5	-7				
Oct	0.66	6.12	6.7									-180	-155	20	13				
Nov	0.76	19.26	16.28									-180	-150	-20	-25				
Dic	0.75	26.65	35.4					-175	-75	5	-7								
T.Max. (Tx)																			
Ene	0.77	10.35	0.6	-175	-130	-10	-25												
Feb	0.78	14	0.75					-180	-140	5	-10								
Mar	0.96	6.04	1.44	-165	-140	-13	-25												
Set	0.57	20.48	0.17									-180	-174	-18	-24				
Oct	0.85	33.34	0.24	-170	-125	3	-3					-160	-145	12	10				
Nov	0.96	7.66	1.37					-180	-115	-8	-25								
Dic	0.86	5	0.11									-115	-75	10	-25				
T.Min (Ti)																			
Ene	0.90	10.68	1.03									-150	-115	20	5				
Feb	0.93	16.66	0.66					-180	-150	5	-13								
Mar	0.90	96.72	0.47	-170	-150	-12	-21												
Abr	0.91	9.95	1.01	-160	-135	-12	-20												
Oct	0.96	19.95	0.33					-170	-140	-8	-17								
Nov	0.41	9.32	0.64									-175	-115	-7	-25				
Dic	0.48	11.41	0.31	-135	-85	-5	-25												

Anexo 3. Resumen del reporte estadístico de las ecuaciones de pronóstico y georeferenciación de cada área del Océano Pacífico considerado para la estación Usnio

Precipitación (Pp)	R ²	F value	ECM	TSM ₁				TSM ₂				TSM ₃				TSM ₄			
				LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y
Ene	0.27	18.27	26.74					-133	-113	-21	-25								
Feb	0.55	9.75	30.94	-180	-172	-20	-24	-93	-84	-15	-21								
Mar	0.40	8.56	44.1					-115	-100	-20	-25	-172	-167	12	8				
Set	0.52	3.56	16.68	-155	-137	-8	-17					-180	-167	-10	-18				
Oct	0.51	11.87	19.23	-114	-103	-21	-25	-180	-175	-20	-25								
Nov	0.26	7.63	46.09	-180	-151	-12	-20												
Dic	0.54	2.48	25.3	-100	-88	-14	-20	-180	-173	20	15								
T.Max (Tx)																			
Ene	0.68	7.86	0.49	-163	-140	15	10 -145		-141	-20	-24								
Feb	0.42	4.69	0.76					-142	-135	20	15	-105	-85	5	-5				
Mar	0.56	6.87	0.95					-180	-168	20	15								
Set	0.35	3.92	0.78	-180	-155	20	15	-116	-113	15	12								
Oct	0.45	8.54	0.73					-120	-115	16	13	-125	-115	-21	-24				
Nov	0.65	7.77	0.85	-90	-75	-15	-25					-135	-120	-20	-25				
Dic	0.48	3.56	2.04	-147	-125	0	-10												
T.Min (Ti)																			
Ene	0.42	6.68	0.88	-120	-102	-12	-15	-117	-109	-19	-24								
Feb	0.31	5.03	1.25													-93	-83	5	0
Mar	0.46	3.01	1.13	-115	-112	-12	-13	-133	-125	10	3								
Set	0.43	5.91	0.97									-135	-100	10	5				
Oct	0.81	20.96	0.62									-165	-110	-10	-25				
Nov	0.42	16.89	0.32									-180	-160	-12	-16				
Dic	0.61	6.22	1.29	-145	-110	0	-15					-155	-140	-18	-25				

Anexo 4. Resumen del reporte estadístico de las ecuaciones de pronóstico y georeferenciación de cada área del Océano Pacífico considerado para la estación Manzana

Precipitación	R ²	F value	ECM	TSM ₁				TSM ₂				TSM ₃				TSM ₄			
				LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y	LON X	LON Y	LAT X	LAT Y
Ene	0.95	5.76	20.92					-175	-170	-5	-15								
Feb	0.42	2.98	44.7									-150	-138	-20	-25				
Mar	0.45	8.54	32.71									-140	-118	15	10				
Set	0.75	1.37	2.37									-180	-145	-5	-18				
Oct	0.52	3.69	13.28									-170	-145	13	9				
Nov	0.45	4.08	21.35									-180	-150	-15	-25				
Dic	0.82	10.37	4.2					-143	-127	-18	-25								
T.Max (Tx)																			
Ene	0.90	9.44	1.5					-146	-118	-15	-25								
Feb	0.88	12.87	1.07					-137	-125	-18	-21								
Mar	0.77	5.59	2.41	-125	-90	-10	-21												
Set	0.97	6.4	1.93	-180	-105	5	-5												
Oct	0.87	46.34	0.8													-175	-140	-10	-24
Nov	0.96	16.34	0.82					-172	-135	-10	-24								
Dic	0.78	55.3	0.47					-173	-158	-10	-17								
T.Min (Ti)																			
Ene	0.90	160.94	0.41					-146	-133	-17	-25								
Feb	0.88	24.87	1.05					-145	-125	-18	-22								
Mar	0.77	9.08	1.86					-158	-130	-14	-21								
Set	0.97	8.27	1.46									-180	-134	-7	-18				
Oct	0.87	51.49	0.7					-173	-125	-10	-24								
Nov	0.96	25.93	0.87									-175	-140	-13	-22				
Dic	0.78	30.71	0.81	-125	-105	-10	-20												

Anexo 5a. Ecuaciones de pronóstico de variables meteorológicas en función de TSM

Para la estación La *Toma* ubicada a 7.062° Latitud Sur y 78.282° Longitud Oeste le corresponden las siguientes ecuaciones:

$$PP_{ene} = 1140.79 - 41.11 TSM_2$$

$$PP_{feb} = -3896.29 + 152.15 TSM_2$$

$$PP_{mar} = 5226.19 - 241.26 TSM_2$$

$$PP_{abr} = 4209.91 - 11.79 TSM_2 - 141.67 TSM_3$$

$$PP_{may} = 1802.5 - 65.9 TSM_3$$

$$PP_{jun} = 1722.43 - 63.68 TSM_2$$

$$PP_{jul} = -380.66 + 13.27 TSM_1$$

$$PP_{ago} = 230.68 - 9.69 TSM_3$$

$$PP_{set} = 82.92 - 3.26 TSM_3$$

$$PP_{oct} = 735.53 - 26.63 TSM_3$$

$$PP_{nov} = 2098.93 - 90.18 TSM_3$$

$$PP_{dic} = -1822.59 + 70.23 TSM_2$$

$$TX_{ene} = -0.01 - 2.21 TSM_3$$

$$TX_{feb} = 0 + 2.91 TSM_1$$

$$TX_{mar} = -0.05 + 11.78 TSM_1 + 1.11 TSM_3 + 2.12 TSM_4$$

$$TX_{abr} = -0.01 + 2.51 TSM_1 - 2.16 TSM_2$$

$$TX_{may} = 0 - 2.95 TSM_2$$

$$TX_{jun} = -0.11 - 1.65 TSM_3$$

$$TX_{jul} = 0.1 + 0.9 TSM_2$$

$$TX_{ago} = 0.01 + 1.37 TSM_2$$

$$TX_{set} = 0.01 - TSM_3$$

$$TX_{oct} = 0 + 0.29 TSM_1 - 2.31 TSM_2$$

$$Tx_{\text{nov}} = 0.01 - 1.38 \text{ TSM}_2 - 7.88 \text{ TSM}_3$$

$$Tx_{\text{dic}} = 0 - 2.45 \text{ TSM}_2$$

$$Ti_{\text{ene}} = 0 - 2.32 \text{ TSM}_2$$

$$Ti_{\text{feb}} = 0 + 1.5 \text{ TSM}_1 - 0.84 \text{ TSM}_2$$

$$Ti_{\text{mar}} = -0.1 - 2.3 \text{ TSM}_4$$

$$Ti_{\text{abr}} = 0 + 6.44 \text{ TSM}_1 - 0.99 \text{ TSM}_2$$

$$Ti_{\text{may}} = 0 - 2.47 \text{ TSM}_2$$

$$Ti_{\text{jun}} = 0 - 4.39 \text{ TSM}_2$$

$$Ti_{\text{jul}} = 0 - 1.02 \text{ TSM}_3$$

$$Ti_{\text{ago}} = 0 + 0.32 \text{ TSM}_2 - 1.06 \text{ TSM}_3$$

$$Ti_{\text{set}} = 0.01 - 2.77 \text{ TSM}_3$$

$$Ti_{\text{oct}} = 0 + 0.36 \text{ TSM}_2 - 2.46 \text{ TSM}_3$$

$$Ti_{\text{nov}} = 0.1 - 2.03 \text{ TSM}_2$$

$$Ti_{\text{dic}} = 0.01 - 2.3 \text{ TSM}_2$$

Anexo 5b. Ecuaciones de pronóstico de variables meteorológicas en función de TSM

Las ecuaciones concernientes a la estación *Usnio* ubicado a 7.089° Latitud Sur y 78.316° Longitud Oeste.

$$PP_{ene} = 3530.59 - 144.96 TSM_1$$

$$PP_{feb} = -973.04 + 91.12 TSM_1 - 63.19 TSM_2$$

$$PP_{mar} = -683.94 + 155.22 TSM_2 - 113.89 TSM_3$$

$$PP_{abr} = -2880.57 + 54.54 TSM_1 + 58.55 TSM_2$$

$$PP_{may} = 26.83 + 7.78 TSM_1 - 7.47 TSM_2$$

$$PP_{jun} = 224.47 + 13.1 TSM_1 - 19.22 TSM_2$$

$$PP_{jul} = -315.32 + 21.16 TSM_1 - 9.58 TSM_3$$

$$PP_{ago} = 85.6 + 17.94 TSM_1 - 19.01 TSM_2$$

$$PP_{set} = -267.07 + 32.07 TSM_1 - 22.71 TSM_3$$

$$PP_{oct} = -2003.8 + 56.8 TSM_1 + 33.03 TSM_2$$

$$PP_{nov} = -2701.6 + 102.8 TSM_1$$

$$PP_{dic} = 586.96 + 26.6 TSM_1 - 40.5 TSM_2$$

$$Tx_{ene} = 0.65 + 1.91 TSM_1 - 1.55 TSM_2$$

$$Tx_{feb} = 53.64 - 0.08 TSM_2 - 1.5 TSM_3$$

$$Tx_{mar} = 74.53 - 2.35 TSM_2$$

$$Tx_{abr} = 140.86 - 4.69 TSM_2$$

$$Tx_{may} = 108.49 - 3.39 TSM_3$$

$$Tx_{jun} = 63.62 + 1.79 TSM_1 - 3.37 TSM_4$$

$$Tx_{jul} = 26.51 + 1.96 TSM_1 - 2.47 TSM_3$$

$$Tx_{ago} = 129.24 - 4.17 TSM_3$$

$$Tx_{set} = -111.18 + 2.28 TSM_1 + 2.27 TSM_2$$

$$Tx_{oct} = 19.34 + 2.43 TSM_2 - 3.15 TSM_3$$

$$Tx_{\text{nov}} = 2.68 + 4.23 \text{ TSM}_1 - 2.77 \text{ TSM}_3$$

$$Tx_{\text{dic}} = -78.87 + 3.52 \text{ TSM}_1$$

$$Ti_{\text{ene}} = -166.78 + 1.72 \text{ TSM}_1 + 5.53 \text{ TSM}_2$$

$$Ti_{\text{feb}} = 59.61 - 2.05 \text{ TSM}_4$$

$$Ti_{\text{mar}} = -35.9 + 2.94 \text{ TSM}_1 - 1.21 \text{ TSM}_2$$

$$Ti_{\text{abr}} = -113.07 + 4.66 \text{ TSM}_1$$

$$Ti_{\text{may}} = 25.2 + 1.53 \text{ TSM}_1 - 2.3 \text{ TSM}_3$$

$$Ti_{\text{jun}} = -94.56 + 4 \text{ TSM}_1$$

$$Ti_{\text{jul}} = -64.47 + 3.14 \text{ TSM}_1 - 0.62 \text{ TSM}_2$$

$$Ti_{\text{ago}} = -28.25 + 4.45 \text{ TSM}_1 - 3.19 \text{ TSM}_2$$

$$Ti_{\text{set}} = 105.35 - 3.51 \text{ TSM}_3$$

$$Ti_{\text{oct}} = 219.09 - 8.41 \text{ TSM}_3$$

$$Ti_{\text{nov}} = 48.18 - 1.51 \text{ TSM}_3$$

$$Ti_{\text{dic}} = 42.63 + 2.68 \text{ TSM}_1 - 4.29 \text{ TSM}_3$$

Anexo 5c. Ecuaciones de pronóstico de variables meteorológicas en función de TSM

Las ecuaciones concernientes a *Manzana* ubicado a 7.118° Latitud Sur y 78.310° Longitud Oeste

$$PP_{ene} = -4380.66 + 151.32 TSM_2$$

$$PP_{feb} = 2403.13 - 93.05 TSM_3$$

$$PP_{mar} = 4122.51 - 162.14 TSM_3$$

$$PP_{abr} = -2491.74 + 101.08 TSM_1$$

$$PP_{may} = 631.39 - 23.38 TSM_5$$

$$PP_{jun} = 1732.73 - 62.67 TSM_2$$

$$PP_{jul} = 64.58 - 2.3 TSM_2$$

$$PP_{ago} = 813.05 - 34.38 TSM_2$$

$$PP_{set} = 188.26 - 6.74 TSM_3$$

$$PP_{oct} = 2377.15 - 85.05 TSM_3$$

$$PP_{nov} = 1663.69 - 66.55 TSM_3$$

$$PP_{dic} = 926.7 - 37.86 TSM_2$$

$$Tx_{ene} = -291.5 + 12 TSM_2$$

$$Tx_{feb} = -199.78 + 8.08 TSM_2$$

$$Tx_{mar} = -256.66 + 11.01 TSM_1$$

$$Tx_{abr} = 275.43 - 8.92 TSM_2$$

$$Tx_{may} = 58.37 - 1.79 TSM_4$$

$$Tx_{jun} = 170.83 - 6.07 TSM_4$$

$$Tx_{jul} = 185.23 - 6.11 TSM_4$$

$$Tx_{ago} = 87.62 + 1.48 TSM_2 - 3.89 TSM_4$$

$$Tx_{set} = -59.92 + 2.76 TSM_1$$

$$Tx_{oct} = 293.49 - 10.69 TSM_4$$

$$Tx_{\text{nov}} = 245.89 - 8.86 \text{ TSM}_2$$

$$Tx_{\text{dic}} = 249.93 - 8.28 \text{ TSM}_2$$

$$Ti_{\text{ene}} = -612.1 + 24 \text{ TSM}_2$$

$$Ti_{\text{feb}} = -303.55 + 11.7 \text{ TSM}_2$$

$$Ti_{\text{mar}} = -294.99 + 10.78 \text{ TSM}_2$$

$$Ti_{\text{abr}} = 296.95 - 10 \text{ TSM}_3$$

$$Ti_{\text{may}} = -17.36 + 0.81 \text{ TSM}_1$$

$$Ti_{\text{jun}} = 67.8 - 2.59 \text{ TSM}_2$$

$$Ti_{\text{jul}} = 170.96 - 6.02 \text{ TSM}_2$$

$$Ti_{\text{ago}} = 108.6 + 1.37 \text{ TSM}_1 - 5.18 \text{ TSM}_2$$

$$Ti_{\text{set}} = 288.34 - 10.21 \text{ TSM}_3$$

$$Ti_{\text{oct}} = 304.4 - 11.6 \text{ TSM}_2$$

$$Ti_{\text{nov}} = 238.7 - 8.92 \text{ TSM}_3$$

$$Ti_{\text{dic}} = -161.14 + 6.82 \text{ TSM}_1$$