



دانشگاه آزاد اسلامی واحد اهر
فصلنامه علمی-پژوهشی فضای جغرافیایی

سال شانزدهم، شماره ۵۶
زمستان ۱۳۹۵، صفحات ۱۸۵-۲۰۰

رضا دهقانی^۱
امیر پورحقی^۲
حسن ترابی^۳

پیش‌بینی نوسانات سطح آب زیرزمینی با استفاده از شبکه‌های بیزین (مطالعه موردی: دشت نورآباد- لرستان)

تاریخ پذیرش: ۱۳۹۴/۰۶/۰۹

تاریخ دریافت: ۱۳۹۳/۱۰/۰۵

چکیده

در بررسی مسائل هیدروژئولوژی متغیر سطح ایستابی از اهمیت بسیار بالایی برخوردار است؛ بنابراین تحقیق و پژوهش در تخمین نقاط فاقد اطلاعات ضروری می‌باشد. در این پژوهش اطلاعات نقاط فاقد آمار دشت نورآباد واقع در استان لرستان که دارای ۱۱ چاه مشاهده‌ای بوده به روش‌های درون‌یابی از جمله زمین‌آمار (کرجینگ و کوکریجینگ) محاسبه شد. همچنین از مدل‌های شبکه‌های بیزین و شبکه‌های عصبی مصنوعی جهت پیش‌بینی نوسانات سطح آب زیرزمینی استفاده گردید. برای این منظور طول و عرض جغرافیایی در مقیاس زمانی ماهانه به‌عنوان ورودی و نوسانات سطح آب زیرزمینی به‌عنوان پارامتر خروجی انتخاب شد. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا و ضریب نش ساتکلیف برای ارزیابی و عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج حاصله نشان داد مدل شبکه بیزین دارای ضریب همبستگی (۰/۸۸۰)، ریشه میانگین مربعات خطا (۰/۰۲۴m) و نیز

E-mail: reza.dehghani67@yahoo.com

E-mail: pourhaghiamir@yahoo.com

۱- دانشجوی دکتری سازه آبی، دانشگاه لرستان.

۲- دانشجوی دکتری منابع آب، دانشگاه چمران اهواز.

۳- دانشیار گروه مهندسی آب، دانشگاه لرستان.

معیار نش ساتکلیف (۰/۹۰۰) در مرحله صحت سنجی توانسته با دقت قابل قبولی به تخمین نوسانات سطح آب پردازد.

کلید واژه‌ها: آب‌های زیرزمینی، زمین‌آمار، درون‌یابی، شبکه بیزین، شبکه عصبی مصنوعی.

مقدمه

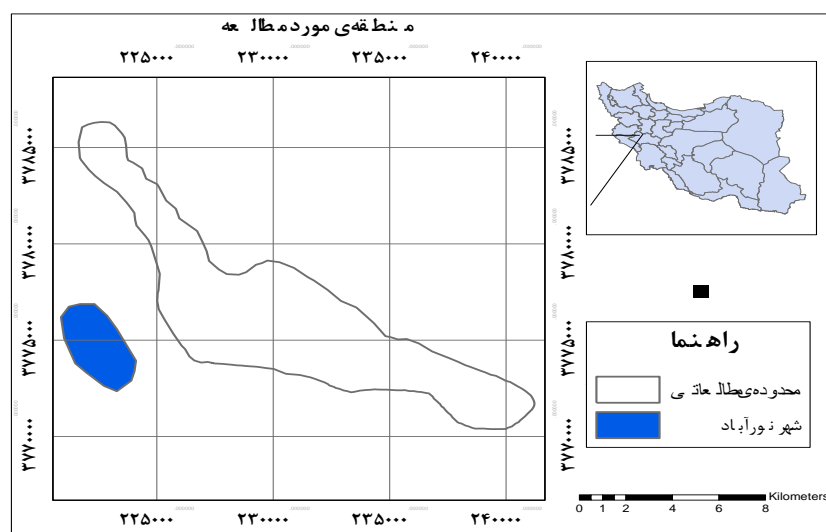
باتوجه به رشد روزافزون جمعیت و ضرورت استفاده بهینه از منابع آب، تأمین بیش‌ترین مقدار ممکن آب‌های زیرزمینی برای رفع نیازهای همه انسان‌ها از اهمیت ویژه‌ای برخوردار است. در بیش‌تر مناطق کشور برای بررسی اطلاعات سطح ایستابی یک دشت از طریق پیژومترهای مشاهده‌ای موجود در منطقه که توسط وزارت نیرو با حفظ استانداردهای جهانی جهت آماربرداری ماهانه حفر شده است، با اندازه‌گیری سطح آب پیژومتر نسبت به سطح زمین، جمع‌آوری می‌شوند. هدف از بررسی تغییرات مکانی، انتخاب روش مناسب درون‌یابی برای تخمین نوسانات سطح آب زیرزمینی است. منظور از بررسی تغییرات مکانی نوسانات سطح آب زیرزمینی، برداشت بهینه از منابع آب زیرزمینی می‌باشد. امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد، شبکه‌های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی که توانایی آن در تقریب الگوهای یک مساله سبب افزایش دامنه کاربرد این شبکه‌ها شده است. طی سال‌های اخیر استفاده از روش شبکه‌های عصبی در مطالعات نوسانات سطح آب زیرزمینی مورد توجه محققان قرار گرفته است که از جمله می‌توان به موارد ذیل اشاره نمود:

در پژوهشی رحمانی (۱۳۹۰) برای شبیه‌سازی منابع آب زیرزمینی دشت عقیلی از مدل‌های شبکه عصبی مصنوعی و تفاضلات محدود استفاده کرد. مقایسه نتایج نشان داد که شبکه عصبی مصنوعی نسبت به مدل ریاضی با دقت قابل توجهی سطح آب زیرزمینی را پیش‌بینی نموده است. از سوی دیگر زمانی احمد محمودی (۱۳۹۱) از تلفیق مدل شبکه عصبی مصنوعی بهینه شده با الگوریتم ژنتیک و روش زمین‌آمار برای تخمین تراز سطح ایستابی دشت‌های دزفول، زیدون و رامهرمز استفاده کرد. نتایج این تحقیق نشان داد تلفیق این دو مدل قابلیت بسیار بالایی در تخمین سطح آب زیرزمینی این دشت‌ها دارد. در پژوهشی دیگر رجانی و ویرس (۲۰۰۷) با کاربرد مدل‌های بیزین و با در نظر گرفتن عدم قطعیت‌های موجود به تخمین تراز سطح آب در جریان رود راین پرداختند. نتایج حاصل از این تحقیق نشان داد به کمک این روش با یک ریسک قابل قبول می‌توان تصمیم‌گیری در شرایط عدم قطعیت را برای تخمین جریان رودخانه تسهیل نمود. همچنین در پژوهشی بوستانی و همکاران (۲۰۰۷) بارش و سطح آب را در بوداپ مالزی با استفاده از تکنیک شبکه‌های عصبی پیش‌بینی کردند. نتایج ایشان نشان داد که شبکه‌های عصبی مصنوعی با دقت ۹۶/۴ درصد قابلیت پیش‌بینی بارش را در رودخانه مورد مطالعه دارد. رکانت (۲۰۰۹) عملکرد

شبکه عصبی استاندارد FFN که با الگوریتم لونبرگ-مارکورت (LM) آموزش داده شده، برای پیش‌بینی نوسانات سطح آب زیرزمینی در حوضه آبریز می‌شی وارم حیدرآباد هند را مورد آزمایش قرار دادند. نتایج این تحقیق نشان داد که مدل مذکور بهترین انطباق و روند پیش‌بینی با داده‌های مشاهداتی دارد. از سوی دیگر استیل (۲۰۰۹) در مطالعه‌ای کاربرد شبکه‌های عصبی مصنوعی را در زمینه‌ی ژئوهیدرولوژی مورد بررسی قرار داد. وی کاربرد انواع شبکه‌های عصبی را با استفاده از الگوریتم‌های متعدد مورد تحلیل قرار داده و بیان داشت که شبکه‌های پیشرو همراه با تاخیر زمانی موثرترین نوع شبکه در زمینه ژئوهیدرولوژی هستند. صادقی حصار (۲۰۱۲) قابلیت بالای شبکه بیزین را با استفاده از الگوریتم یادگیری جستجوی ممنوع در تخمین رواناب براساس آمار و اطلاعات بارندگی ماهانه مورد بررسی قرار داده و نشان دادند شبکه بیزین روش مفیدی جهت تخمین رواناب است. در مجموع با توجه به پژوهش‌های انجام شده و همچنین اهمیت دشت نورآباد از لحاظ شرب و کشاورزی نوسانات سطح آب زیرزمینی به منظور پیش‌بینی و اقدامات مدیریتی جهت بهبود با استفاده از شبکه عصبی مصنوعی از جمله اهداف پژوهش حاضر در نظر گرفته شده است.

منطقه مورد مطالعه

منطقه مورد مطالعه شهرستان نورآباد واقع در استان لرستان می‌باشد. این منطقه بین طول‌های $34^{\circ} 4' 48''$ شرقی و عرض‌های $47^{\circ} 58' 12''$ شمالی واقع شده است. محدوده مطالعاتی نورآباد دارای ۸۱۱ کیلومتر مربع مساحت است که از این مقدار ۱۵۹ کیلومتر مربع دشت با ارتفاع متوسط ۱۶۲۰ متر و ۶۵۲ کیلومتر مربع با ارتفاع متوسط ۲۲۴۰ متر می‌باشد. این دشت دارای یک سفره زیرزمینی آبرفتی می‌باشد و دارای وضعیت آب سطحی و زیرزمینی نسبتاً خوبی می‌باشد. در (شکل ۱) نشان داده شده است و همچنین در (جدول ۱) مشخصات چاه‌های مشاهداتی نشان داده شده است.



شکل ۱: موقعیت منطقه مورد مطالعه

جدول ۱- جاه‌های مشاهده‌ای شهرستان نورآباد

ارتفاع	مختصات ایستگاه (UTM)		ایستگاه
۱۹۰۳	۳۷۸۶۲۳۷	۷۶۷۸۵۸	ایمان آباد رجبان
۱۸۸۲	۳۷۷۱۴۸۷	۲۳۸۰۷۶	بگوردی سفلی
۱۹۲۴	۳۷۶۷۵۴۳	۲۳۷۳۶۱	تاج امیر
۱۸۲۰	۳۷۸۵۹۸۷	۷۶۳۳۴۹	چال صید علی
۱۹۰۹	۳۷۶۹۶۰۱	۲۳۸۰۲۰	چراغ
۱۸۰۱	۳۷۹۲۱۹۸	۷۵۷۳۵۷	چمن بوله
۱۹۲۶	۳۷۶۹۴۰۶	۲۴۱۴۹۸	جعفر بیگی سفلی
۱۸۳۰	۳۷۷۱۲۱۱	۷۷۱۸۲۹	حاجی آباد
۱۸۲۹	۳۷۷۲۳۷۴	۲۲۴۳۴۹	حسین آباد
۱۸۱۹	۳۷۷۹۱۳۴	۲۲۷۴۲۳	سراب غضنفر
۱۶۴۲	۳۷۷۷۰۸۶	۷۳۸۷۱۹	شرف‌آباد بالا

روش‌های درون‌یابی

در این پژوهش از روش‌های کریجینگ (kriging) و با حالت‌های ساده (sk: simple kriging)، عمومی (uk: universal kriging) و معمولی (ok: ordinary kriging) و روش کوریجینگ (co-kriging) شامل روش کوکریجینگ ساده (sco: simple co kriging)، کوکریجینگ عمومی (uco: universal co kriging)، کوکریجینگ معمولی (oco: ordinary co kriging) با مدل‌های دایره‌ای (circular)، نمایی (exponential)، کروی (spherical) و گوسین (gaussian) استفاده گردید. در این روش‌ها، مقادیر برآوردی از مجموع حاصل ضرب یک فاکتور وزنی در مقادیر نقاط مشاهده‌ای به دست می‌آید. معادله کلی روش‌های مختلف درون‌یابی به صورت زیر است.

$$Z^*(x_i) = \sum_{i=1}^n \gamma_i \cdot z(x_i) \quad \text{رابطه (۱)}$$

که در آن $Z^*(x_i)$ مقادیر متغیر مکانی برآورد شده $Z(x_i)$ مقادیر متغیر مکانی برآورد شده در x_i است و γ_i وزن آماری که به نمونه x_i نسبت داده می‌شود و بیانگر اهمیت نقطه‌ی x_i در برآورد است. تفاوت عمده روش‌های مختلف میان‌یابی در برآورد فاکتور وزنی یاد شده است.

روش کریجینگ

کریجینگ یکی از روش‌های پیشرفته زمین‌آمار است که بر اساس نیم متغیر نما استوار می‌باشد. نیم متغیر نما یکی از روش‌های محاسبه‌ی تغییرات مکانی است که هدف اصلی از برقرار کردن تابع آن شناسایی ساختار تغییرپذیری متغیر نسبت به فاصله مکانی می‌باشد، در صورتی که آمار کلاسیک دارای چنین قابلیت‌هایی نمی‌باشد. از نظر تعریف، اگر

واریانس بین نقاطی با فاصله h کوچک باشد، نشانه وابستگی بیش‌تر متغیر بین آن نقاط است. این واریانس وابسته به فاصله، نیم متغیر نما نامیده می‌شود که آن را با (γh) نشان می‌دهند. تابع نیم متغیر نما، تغییرات یک پارامتر را با در نظر گرفتن فاصله به صورت معادله زیر نشان می‌دهد:

$$\gamma(h) = \sum_{i=1}^{n(h)} z(x_i) - z(x_i+h) J^2 \quad \text{رابطه (۲)}$$

که در آن $z(x_i)$ و $z(x_i+h)$ مقادیر متغیر به ترتیب در نقاط x_i و x_i+h و $N(h)$ تعداد جفت نمونه‌های به کار رفته است؛ به عبارت دیگر، کریجینگ تخمین‌گری نارایب است که تنها یک متغیر را پیش‌بینی می‌نماید. شرط نارایب بودن در سایر روش‌های تخمین، نظیر روش فاصله معکوس هم اعمال می‌شود ولی ویژگی روش کریجینگ این است که در عین نارایب بودن، واریانس تخمین نیز حداقل می‌باشد؛ به عبارت دیگر در این روش از اطلاعات موجود به بهترین نحو استفاده شده است؛ بنابراین کریجینگ به همراه هر تخمین، مقدار خطای آن را نیز ارائه می‌دهد که با استفاده از این ویژگی منحصر به فرد می‌توان قسمت‌هایی که در آنجا خطا زیاد است و در آن به اطلاعات بیش‌تری نیاز است را مشخص نمود (گل محمدی و همکاران، ۱۳۸۶).

روش کو کریجینگ

در برخی موارد ممکن است از یک متغیر به اندازه کافی نمونه‌برداری نشده باشد و بر اساس نمونه‌های موجود نتوان تخمین را به دقت مورد نظر انجام داد. در چنین مواردی می‌توان با در نظر گرفتن رابطه مکانی بین این دو متغیر و متغیر دیگری که از آن به خوبی نمونه‌گیری شده است تخمین را اصلاح کرد. البته به دلیل مشکلاتی مدل‌سازی تغییر نمای متقابل متغیر ها وجود دارد کوکریجینگ به لحاظ کاربردی اعتبار کافی را پیدا نکرده است. به عبارت دیگر همان‌طور که در آمار کلاسیک نیز روش‌های چند متغیره وجود دارد، در زمین‌آمار نیز می‌توان به روش کوکریجینگ و بر اساس همبستگی موجود بین متغیرهای مختلف رابطه چند متغیره مناسبی را تخمین زد. معادله کوکریجینگ به شرح زیر می‌باشد:

$$Z^*(x_i) = \sum_{i=1}^n \gamma_i x_i + \sum_{k=1}^n \gamma_k y(x_k) \quad \text{رابطه (۳)}$$

که در آن $Z^*(x_i)$ مقدار تخمین زده شده برای (x_i) ، (γ_i) وزن مربوط به متغیر (z) ، (γ_k) وزن مربوط به متغیر کمکی $y(x_k)$ ، مقدار مشاهده شده متغیر اصلی و $\gamma(x_k)$ مقدار مشاهده شده متغیر کمکی می‌باشد برای تخمین با این روش و برای محاسبه اوزان مربوط، نیاز به محاسبه‌ی تغییر نمای متقابل به صورت زیر می‌باشد.

$$\gamma(z)y = \frac{1}{2} n [z(x_i+h) - z(x_i)] \times [y(x_k+h) - y(x_k)] \quad \text{رابطه (۴)}$$

که در آن $h(z, y)$ تغییر نمای متقابل بین متغیرهای z, y ، $Z(X_i)$ متغیر مشاهده شده و $Y(X_k)$ متغیر کمکی می‌باشد. توسعه این روش بیش تر برای شرایط مناسب پیشنهاد شده است که از یک متغیر تعداد محدودی نمونه در دسترس باشد. محل‌هایی که در آن کمبود نمونه وجود دارد به کمک متغیر ثانوی و با استفاده از همبستگی متقابل بین متغیرهای اصلی و ثانوی تخمین زده می‌شوند. وقتی تعدادی متغیر وابسته به هم تخمین زده می‌شوند، از نظر تئوری کوکریجینگ نسبت به سایر روش‌های کوریجینگ ارجحیت دارد. حتی وقتی که از همه متغیرها به اندازه کافی نمونه در دسترس باشد باز هم کوکریجینگ ترکیبی از روش کوریجینگ یک متغیره است. در این تحقیق ما از روش‌های کوریجینگ و کوکریجینگ استفاده شده است (گل محمدی و همکاران، ۱۳۸۶).

شبکه‌های بیزین

شبکه‌های بیزین که با نام شبکه‌های اعتقاد (باور) هم شناخته می‌شوند، متعلق به خانواده مدل‌های گرافیکی احتمالاتی هستند. این ساختارهای گرافیکی برای نشان دادن اطلاعات در یک حوزه دارای عدم قطعیت به کار می‌روند. به‌طور خاص هر گره در گراف نشان‌دهنده یک متغیر تصادفی است و شاخه‌ها (کمان) وابستگی‌های احتمالاتی بین متغیرها را نشان می‌دهند. این وابستگی‌های شرطی غالباً به وسیله روش‌های آماری و احتمالاتی مشخص ارزیابی می‌شوند. شبکه‌های بیزین اصولی از نظریه گراف، نظریه احتمالات، علوم کامپیوتر و آمار را باهم ترکیب می‌کنند.


به‌طور کلی مدل‌های گرافیکی با شاخه‌های بدون جهت، میدان‌های تصادفی مارکوف یا شبکه‌های مارکوف نامیده می‌شوند. این شبکه‌ها یک تعریف ساده برای استقلال بین متغیرها بر مبنای مفهوم لایه مارکوف فراهم می‌کنند. شبکه‌های مارکوف در زمینه‌هایی نظیر فیزیک آماری و بینایی کامپیوتر بسیار مشهور هستند.

شبکه‌های بیزین متعلق به ساختار دیگری از مدل‌های گرافیکی به نام گراف‌های غیرمدور جهت‌دار هستند که در زمینه‌های آماری، یادگیری ماشینی و هوش مصنوعی بسیار مشهور هستند. شبکه‌های بیزین نمایش و محاسبات موثری از توزیع احتمالاتی مشترک به روی یک سری متغیر تصادفی را فراهم می‌آورند. به علاوه شبکه‌های بیزین شدت ارتباط بین متغیرها را به صورت کمی مدل می‌کنند که اجازه می‌دهند با دسترسی به اطلاعات جدید، اعتقاد شرطی در مورد آن‌ها به صورت خودکار به‌روزرسانی شود.

شبکه‌های بیزین مدل‌های بسیار معروفی در دهه اخیر شده‌اند. این شبکه‌ها کاربردهای بسیاری در زمینه‌های مختلف نظیر یادگیری ماشینی، کاوش متن، پردازش زبان طبیعی، شناسایی صدا، پردازش سیگنال، بیوانفورماتیک، کدهای کنترل خطا، تشخیص پزشکی، پیش‌بینی هوا و شبکه‌های سلولی پیدا کرده‌اند.

بنابراین شبکه‌های بیزین^۴ مدل‌های گرافیکی هستند که برای استدلال در مواردی که پیچیدگی و عدم قطعیت وجود دارد به کار می‌روند و یا به عبارتی گرافی است که متغیرهای تصادفی و وابستگی آن‌ها را نمایش می‌دهد (هکرمن،

۱۹۹۷). در این گراف گره‌ها نشانگر متغیرهای تصادفی گسسته یا پیوسته هستند و کمان‌های جهت‌داری که هر جفت از گره‌ها را به یکدیگر متصل می‌کنند وابستگی بین متغیرها را نمایش می‌دهد. در واقع این شبکه گراف جهت‌داری است که هیچ دوری در آن وجود ندارد (کن و همکاران، ۲۰۰۶). نمونه‌ای از گراف ساده در (شکل ۲) نشان داده شده است.



شکل ۲: گراف ساده شبکه بیزین

در مورد ساختار شبکه بیزین اگر مجموعه‌ای شامل n متغیر به صورت $\{x_1, x_2, x_3, \dots, x_n\}$ داشته باشیم که هر x_i یک متغیر تصادفی باشد و گره‌های والد این متغیر با $\text{parent}(x_i)$ نشان داده شوند، احتمال هر رویداد مانند $X=(x_1, x_2, x_3, \dots, x_n)$ به صورت زیر محاسبه می‌گردد.

$$P(x_1 + \dots + x_n) = \prod_{i=1}^n P(x_i | \text{parents}(x_i)) \quad \text{رابطه (۵)}$$

بعد از ایجاد شبکه، مقدار روابط بین گره‌های متصل به هم به دست می‌آید مقدار احتمال شرطی مربوط به هر متغیر در جدولی به نام جدول احتمال شرطی قرار می‌گیرد. هر گره یک جدول احتمال شرطی دارد که برای هر ترکیب از مقادیر والد هایش، احتمال شرطی هر کدام از این مقادیر را نگه می‌دارد و سپس توزیع‌های احتمال بعدی برای هر گره محاسبه می‌شود که این توزیع احتمال باور نامیده می‌شود.

شبکه عصبی مصنوعی


در حالت کلی شبکه عصبی شامل سه لایه می‌باشد (شکل ۳). لایه ورودی که وظیفه آن معرفی پارامترها به شبکه می‌باشد، لایه خروجی محل استقرار پارامترهای خروجی شبکه و لایه پنهان، لایه‌های مابین لایه ورودی و خروجی می‌باشند که نقش پردازشگری اطلاعات را بر عهده دارد. یک شبکه عصبی مصنوعی علائم را از واحدهای ورودی دریافت کرده و این سیگنال‌ها در طول شبکه انتشار یافته و در نهایت به سوی نرون خروجی حرکت می‌نمایند. پارامترهای کنترلی اصلی مدل‌های شبکه عصبی مصنوعی مقاومت‌های اتصالی بین نرون‌ها می‌باشند که به‌عنوان وزن‌ها و گرایش‌ها^۵ نامیده می‌شوند. هر نرون مطابق (شکل ۴) خروجی‌های وزن‌دار شده نرون‌های لایه قبلی را

دریافت و مجموع آنها، ورودی خالص به نرون z_j (net_j) را مطابق رابطه زیر تولید می‌کند.


$$\text{net}_j = \sum w_{j,i} x_i + b_j \quad \text{رابطه (۶)}$$

که در رابطه فوق net_j سطح محرک سلول عصبی z_j یا ورودی خالص به نرون z_j ، $w_{j,i}$ وزن اتصالی بین گره‌های i و x_i ، z_j ورودی به گره i و b_j بایاس گره z_j می‌باشد.

$$y_j = f(\text{net}_j) = \frac{1}{1 + \exp^{-(\text{net}_j)}} \quad \text{رابطه (۷)}$$



شکل ۳: نمای کلی یک شبکه عصبی مصنوعی سه لایه



شکل ۴: شماتیک یک نرون مصنوعی و چگونگی دریافت سیگنال‌های ورودی و تولید سیگنال خروجی y_i

لایه‌های مختلف در شبکه عصبی و همچنین نرون‌های موجود در لایه‌ها می‌توانند دارای توابع محرک متفاوت یا یکسانی باشند. شبکه‌های عصبی از نظر ساختار و ارتباطات بین نرون‌ها به گروه‌های مختلفی تقسیم می‌شوند. شبکه

پرسپترون چند لایه رایج‌ترین مدل شبکه عصبی استفاده شده در مسائل مهندسی آب می‌باشد که برای آموزش این شبکه از الگوریتم پس انتشار خطا که یک روش یادگیری با ناظر است استفاده می‌شود. منظور از آموزش یک شبکه عصبی، تنظیم پارامترهای شبکه (وزن‌ها و بایاس‌ها) با ارائه الگوهای آموزش است به طوری که با ارائه مجدد همان الگوها خطای حاصل بین پاسخ مطلوب و شبکه حداقل گردد. به طور کلی در شبکه پرسپترون چندلایه عموماً دو نوع سیگنال، یعنی سیگنال‌هایی که در مسیر رفت (از لایه ورودی به طرف لایه خروجی) و دیگری سیگنال‌های برگشت (از لایه خروجی به طرف لایه ورودی) حرکت می‌کنند، استفاده می‌شود که به ترتیب به نام سیگنال تابعی و خطا معروف هستند. تنظیم پارامترها در شبکه پرسپترون چندلایه توسط سیگنال خطا و سیگنال ورودی صورت می‌گیرد. تعیین تعداد لایه‌ها و نرون‌های موجود در آن‌ها از مهم‌ترین مسائل در مدل‌سازی با شبکه عصبی مصنوعی است. توکار و جانسون رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی را توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کردند. از طرفی توابع محرک موجود در نرم‌افزار Matlab جهت به کارگیری در لایه‌های پنهان و خروجی توابع محرک سیگموئید، تانژانت هیپربولیک، سکانت هیپربولیک و گاوسین می‌باشند. (صف شکن، ۱۳۹۰).

معیارهای ارزیابی

در این تحقیق ارزیابی دقت و قابلیت مدل‌ها با استفاده از نمایه‌های ضریب همبستگی (CC)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش ساتکلیف (NS) طبق روابط زیر محاسبه می‌گردد. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

$$CC = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad \text{رابطه (۸)}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad \text{رابطه (۹)}$$

$$NS = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{y})^2} \quad \text{رابطه (۱۰)}$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام‌های زمانی، \bar{x} و \bar{y} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی-محاسباتی نسبت به زمان نیز جهت مقایسه و تحلیل بیش‌تر نتایج استفاده شده است.

یافته‌ها و بحث

در این تحقیق به منظور بررسی نتایج مدل از داده‌های ماهانه ۱۱ چاه‌های پیزومتری دشت نورآباد در سال ۱۳۸۱ استفاده گردید. آمار طول و عرض جغرافیایی و ارتفاع چاه‌های مذکور را بروش های زمین‌آمار (کریجینگ و کوکریجینگ) آمار پیزومترهای فاقد اطلاعات محاسبه و ۲۲۰ نقطه دارای آمار ایجاد گردید. مقادیر طول و عرض جغرافیایی به‌عنوان پارامترهای ورودی و نوسانات سطح آب به‌عنوان خروجی مدل انتخاب گردید. تعداد ۸۰ درصد از داده‌ها (۱۷۶ رکورد)، به‌منظور آموزش و ۲۰ درصد مابقی (۴۴ رکورد)، برای صحت‌سنجی انتخاب گردید یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به‌صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (ژو و همکاران، ۲۰۰۷). برای نرمال‌سازی داده‌های تحقیق از رابطه ۱۱ استفاده شده است:

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه (۱۱)}$$

که در آن X_n مقدار نرمال شده ورودی X_i ، X_{\max} و X_{\min} به ترتیب حداکثر و حداقل داده‌ها می‌باشد.

نتایج شبکه عصبی مصنوعی

به‌منظور مدل‌سازی نوسانات سطح آب زیرزمینی دشت نورآباد از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون چندلایه با لایه پنهان با تعداد نرون‌های متفاوت استفاده شده است. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس انتشار خطا به‌نام الگوریتم لونبرگ-مارکووارت به‌دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه (های) مخفی استفاده گردید. تعداد تکرارهای لازم در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا مورد ارزیابی قرار گرفته است. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مساله مورد بررسی مشخص شده، حال آن‌که تعداد نرون‌های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید.

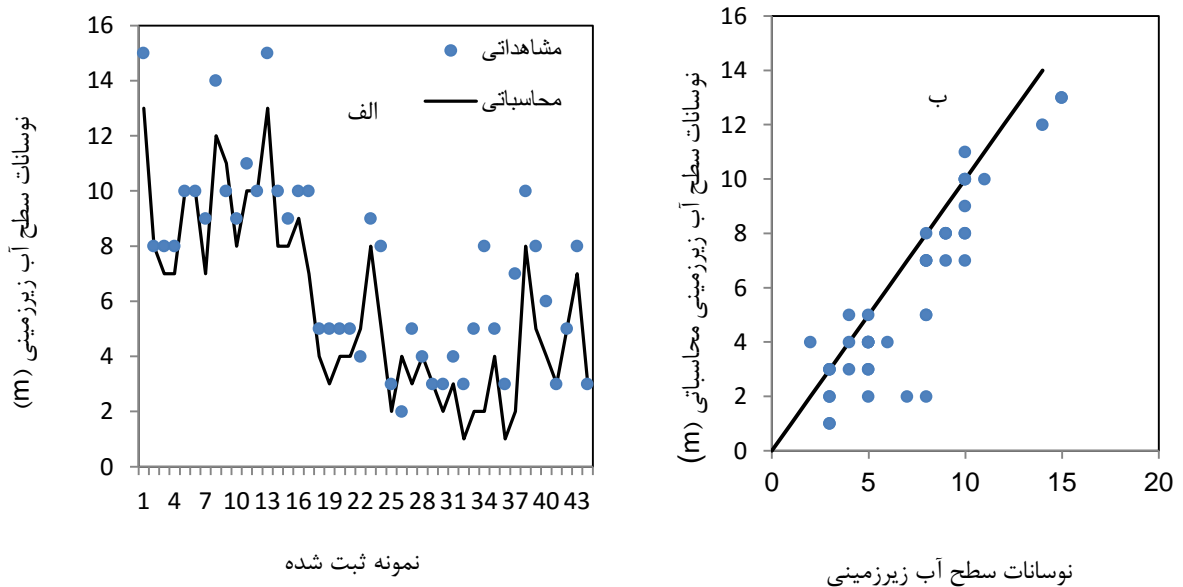
روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه می‌یابد که افزایش نرون‌های بیش‌تر تاثیری در بهبود خطا نداشته باشد که شبکه‌ای با ۲ نرون در لایه پنهان اول به‌عنوان بهترین شبکه در فرآیند

مدل‌سازی حاصل شد. در (جدول ۲) نتایج حاصل از مقایسه عملکرد ساختارهای مختلف به‌کار رفته به همراه پارامترهای آماری داده‌های بخش آموزش و صحت سنجی ارائه شده است. همان‌طور که در (جدول ۲) مشاهده می‌شود ساختار شماره ۱ با بیش‌ترین ضریب همبستگی $CC=0/891$ و کم‌ترین ریشه میانگین مربعات خطا $RMSE = 0/252$ m و $NS=0/875$ در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل‌سازی نوسانات سطح آب زیرزمینی مناسب‌تر خواهد بود.

جدول ۲- ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی مصنوعی و شاخص‌های آماری در مراحل آموزش و صحت سنجی

شماره	ساختار	تابع محرک		آموزش			صحت سنجی		
		لایه پنهان	لایه خروجی	CC	RMSE (m)	NS	CC	RMSE (m)	NS
۱	۷-۲-۱	تانزانته هیپربولیک	خطی	۰/۸۱۴	۰/۲۳۵	۰/۸۷۵	۰/۸۳۰	۰/۲۵۲	۰/۸۹۱
۲	۷-۳-۱	تانزانته هیپربولیک	خطی	۰/۸۰۸	۰/۲۳۴	۰/۸۷۴	۰/۸۲۹	۰/۲۵۳	۰/۸۸۹
۳	۷-۴-۱	تانزانته هیپربولیک	خطی	۰/۷۸۲	۰/۲۳۲	۰/۸۷۴	۰/۸۲۸	۰/۲۵۳	۰/۸۸۸
۴	۷-۵-۱	تانزانته هیپربولیک	خطی	۰/۶۳۲	۰/۲۳۴	۰/۸۷۳	۰/۸۲۹	۰/۲۵۳	۰/۸۸۹
۵	۷-۶-۱	تانزانته هیپربولیک	خطی	۰/۷۴۶	۰/۲۳۴	۰/۸۷۳	۰/۸۲۸	۰/۲۵۴	۰/۸۸۹
۶	۷-۸-۱	تانزانته هیپربولیک	خطی	۰/۷۳۶	۰/۲۳۳	۰/۸۷۴	۰/۸۲۷	۰/۲۵۴	۰/۸۸۸
۷	۷-۱۰-۱	تانزانته هیپربولیک	خطی	۰/۷۵۴	۰/۲۳۳	۰/۸۷۴	۰/۸۲۹	۰/۲۵۳	۰/۸۸۹
۸	۷-۱۱-۱	تانزانته هیپربولیک	خطی	۰/۷۹۴	۰/۲۳۴	۰/۸۷۳	۰/۸۲۹	۰/۲۵۴	۰/۸۸۹
۹	۷-۱۲-۱	تانزانته هیپربولیک	خطی	۰/۷۸۶	۰/۲۳۳	۰/۸۷۳	۰/۸۲۹	۰/۲۵۳	۰/۸۸۹
۱۰	۷-۱۴-۱	تانزانته هیپربولیک	خطی	۰/۸۰۳	۰/۲۳۳	۰/۸۷۵	۰/۸۲۸	۰/۲۵۴	۰/۸۸۸
۱۱	۷-۱۶-۱	تانزانته هیپربولیک	خطی	۰/۷۹۹	۰/۲۳۳	۰/۸۷۴	۰/۸۳۰	۰/۲۵۳	۰/۸۹۰

در (شکل ۵) نمودار بهترین مدل حاصل شده برای داده‌های بخش صحت سنجی نشان داده شده است. همان‌طور که از شکل (۵-ب) مشخص است مقادیر تخمینی و مشاهداتی به غیر از چند نقطه روی خط نیمساز پراکنده شده و این امر دلالت بر برابری مقادیر مشاهداتی و محاسباتی براساس خط $(y=x)$ می‌باشد. در شکل (۵-الف) نیز تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان نشان داده شده است، این شکل نشان می‌دهد که شبکه عصبی مصنوعی در تخمین برخی مقادیر حداقل، حداکثر و میانی عملکرد خوبی نداشته، به‌طوری که این مقادیر را بیش‌تر یا کم‌تر از مقدار واقعی‌شان تخمین زده است.




شکل ۵: نمودار حاصل از مقادیر بهینه مدل شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله صحت سنجی (الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان (ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی

نتایج شبکه بیزین


در این پژوهش ساختار شبکه بیزین از بین الگوریتم‌های K2 و BDeu از الگوریتم K2 که مناسب‌ترین پارامتر الگوریتم یادگیری شبکه می‌باشد برای ایجاد شبکه استفاده گردید. همچنین از میان متدهای موجود برای ساخت شبکه، از معمولی‌ترین متد Greedy Thick Thinning جهت الگوریتم یادگیری استفاده شده است. برای استنتاج شبکه نیز الگوریتم Clustering برای نمایش میزان تاثیر هر کدام از پارامترها در نظر گرفته شده است. شبکه عوامل موثر در میزان نوسانات سطح آب زیرزمینی و میزان تاثیر هر کدام از عوامل تاثیر گذار را نمایش می‌دهد. (شکل ۶) شبکه تشکیل شده را نشان می‌دهد. همان‌طور که در (جدول ۳) مشاهده می‌شود شبکه بیزین دارای دقت $CC=0/880$ و ریشه میانگین مربعات خطا $RMSE=0/024$ m و ضریب نش-ساتکلیف $NS=0/900$ در مرحله صحت سنجی می‌باشد.

جدول ۳- نتایج حاصل از روش بیزین

مرحله	NS	(RMSEm)	CC
آموزش	0/810	0/125	0/746
صحت سنجی	0/880	0/024	0/900



شکل ۶: ساختار شبکه بیزین برای پیش‌بینی نوسانات سطح آب زیرزمینی



شکل ۷: نمودار حاصل از مقادیر بهینه مدل شبکه بیزین برای داده‌های ثبت شده مرحله صحت سنجی (الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان (ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی


در (شکل ۷) نمودار بهترین مدل حاصل شده برای داده‌های بخش صحت سنجی نشان داده شده است. همان‌طور که از (شکل ۷-ب) مشخص است مقادیر تخمینی و مشاهداتی به غیر از چند نقطه روی خط نیمساز قرار نگرفته است و این امر دلالت بر برابری مقادیر مشاهداتی و محاسباتی براساس خط $(y=x)$ می‌باشد. در شکل (۷-الف) نیز تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان نشان داده شده است، این شکل نشان می‌دهد که شبکه بیزین در تخمین برخی مقادیر حداقل، حداکثر و میانی عملکرد خوبی داشته، به‌طوری که این مقادیر را نزدیک به مقدار واقعی‌شان تخمین زده است؛ که با نتایج صادقی حصار (۲۰۱۲) و قربانی و دهقانی (۱۳۹۲) همخوانی دارد و در تبیین این نتایج می‌توان بیان نمود شبکه بیزین با استفاده از الگوریتم یادگیری K2 که به‌عنوان الگوریتم یادگیری ماشینی بوده، الگوهای مورد نظر را از یک مجموعه داده‌ها با استفاده از دانش قبلی در مورد الگوها یا اطلاعات آماری داده‌ها، جداسازی می‌نماید همچنین یادگیری ماشینی با ترکیب قانون احتمالات بیز سبب می‌گردد با میزان خطای کم‌تری محتمل‌ترین الگوی رخداد یک پدیده را انتخاب و بررسی نماید (هکرمن، ۱۹۹۷).

مقایسه عملکرد مدل‌ها

در ادامه با انتخاب جواب بهینه هر کدام از مدل‌ها و مقایسه آن‌ها با یکدیگر مشخص شد، هر سه روش با دقت خوبی می‌توانند میزان نوسانات سطح آب زیرزمینی را شبیه‌سازی کنند. همان‌طور که در (جدول ۴) مشاهده می‌شود از بین مدل‌های به کار رفته مدل شبکه بیزین با بیش‌ترین دقت $CC=0/880$ و کم‌ترین ریشه میانگین مربعات خطا m $RMSE = 0/024$ و بیش‌ترین ضریب نش-ساتکلیف $NS=0/900$ در مرحله صحت سنجی دارا می‌باشد. مقایسه نتایج مدل شبکه بیزین با مدل شبکه عصبی مصنوعی حاکی از نزدیک بودن نتایج این دو مدل می‌باشد. همچنین همان‌طور که در (شکل ۸) قابل مشاهده است شبکه بیزین در تخمین اکثر مقادیر عملکرد قابل قبولی داشته به گونه‌ای که این مقادیر را نزدیک به مقادیر مشاهداتی تخمین زده است.


جدول ۴- نتایج نهایی حاصل از آموزش و صحت سنجی مدل‌های شبکه بیزین و شبکه عصبی مصنوعی

صحت سنجی			آموزش			مدل
CC	RMSE (m)	NS	CC	RMSE (m)	NS	
0/900	0/024	0/880	0/746	0/125	0/810	شبکه بیزین
0/891	0/252	0/830	0/875	0/235	0/814	شبکه عصبی مصنوعی



شکل ۸: نمودار پراکنش و مشاهداتی - محاسباتی مقادیر بهینه مدل شبکه بیزین و شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله

صحت سنجی



شکل ۹: نمودار خطای بهینه هر دو مدل به صورت درصدی از میانگین مقادیر مشاهداتی

در نهایت اختلاف مقادیر مشاهداتی سطح ایستابی و محاسباتی بهینه مدل‌ها به صورت درصدی از میانگین مقادیر مشاهداتی (مقدار خطا)، محاسبه و نمودار آن نسبت به نمونه داده‌های ثبت شده دوره آماری ترسیم گردید (شکل ۹). همان‌طور که در این شکل دیده می‌شود برای هر سه مدل بیش‌تر خطاها در باند ± 1 در صد قرار گرفته است و بیش‌ترین میزان خطای مدل شبکه بیزین و شبکه عصبی مصنوعی به ترتیب ۱ و ۵ درصد از میانگین مقادیر مشاهداتی می‌باشد؛ که در میان مدل‌های مذکور (شبکه بیزین و شبکه عصبی مصنوعی)، مدل شبکه بیزین کم‌ترین میزان خطا را داشته است. در مجموع با توجه به دقت و قابلیت تخمین بالا مدل‌های شبکه بیزین و شبکه عصبی مصنوعی، همبستگی بین مقادیر مشاهداتی و مقادیر محاسباتی مدل‌های مذکور بررسی شده که به ترتیب ۰/۹۰۰ و ۰/۸۹۱ می‌باشد.

نتیجه‌گیری

در پژوهش حاضر سعی بر آن شد عملکرد مدل‌های شبکه بیزین و شبکه عصبی مصنوعی جهت شبیه‌سازی نوسانات سطح آب زیرزمینی با استفاده از داده‌های ماهانه ایستگاه‌های دشت نورآباد (لرستان) مورد ارزیابی قرار گیرد. مقادیر نوسانات سطح ایستابی مشاهداتی با نوسانات سطح ایستابی تخمین زده شده این مدل‌ها با استفاده معیارهای ارزیابی، بررسی گردید. نتایج تحقیق را می‌توان به صورت زیر خلاصه نمود: نتایج تحقیق نشان داد که هر دو روش عملکرد قابل قبولی در تخمین سطح ایستابی دارند. در این میان، مدل شبکه بیزین دقت بالا و خطای ناچیز و قابلیت بسیار بالایی در تخمین اکثر مقادیر از خود نشان داده است. همچنین نتایج تحقیق نشان داد که روش کوکریجینگ ساده با مدل دایره‌ای عملکرد بهتری در درون‌یابی نقاط فاقد آمار سطح آب زیرزمینی در دشت نورآباد داشته است. در مجموع این تحقیق نشان می‌دهد که استفاده از مدل شبکه عصبی مصنوعی و شبکه بیزین می‌تواند در زمینه تخمین نوسانات سطح آب زیرزمینی استفاده شود.

منابع

- رحمانی، غ. ر (۱۳۹۰)، «شبیه‌سازی منابع آب زیرزمینی دشت عقیلی با استفاده از شبکه‌های عصبی مصنوعی و مقایسه آن با نتایج مدل ریاضی تفاضلات محدود»، پایان‌نامه کارشناسی ارشد، دانشکده فنی، دانشگاه شهید چمران اهواز.
- زمانی، احمد؛ محمودی، ر (۱۳۹۱)، «بررسی کاربرد روش ترکیبی زمین‌آمار و شبکه‌های عصبی بهینه شده با الگوریتم ژنتیک در میان‌یابی سطح آب زیرزمینی دشت»، پایان‌نامه کارشناسی ارشد، دانشکده فنی، دانشگاه شهید چمران اهواز.
- صف‌شکن، ف؛ پیرمردیان، ن؛ افشین شریفان، ر (۱۳۹۰)، «شبیه‌سازی آبنمود بارش-رواناب با توجه به الگوی زمانی بارش و استفاده از شبکه عصبی مصنوعی در حوضه آبخیز معروف کسلیان»، *مجله علوم مهندسی آبخیزداری ایران*، شماره ۱۵، صص ۱۰-۱.
- قربانی، م.ع؛ دهقانی، ر (۱۳۹۲)، «کارایی شبکه‌های بیزین در تحلیل عوامل موثر بر میزان کل مواد جامد محلول رودخانه‌ها»، *کنفرانس بین‌المللی عمران و توسعه پایدار*، تبریز، ۲۷ و ۲۸ آذر ۱۳۹۲.
- گل محمدی، گ؛ معروفی، ص؛ محمدی، ک (۱۳۸۶)، «منطقه‌ای نمودن ضریب رواناب در استان همدان با استفاده از روش‌های زمین‌اماری و GIS»، *علوم و فنون کشاورزی و منابع طبیعی*، شماره ۴۶، صص ۵۱۴-۵۰۱.
- Bustmi, R., Bessaih, N., Bong, C., Sohaili, S., (2007), "Artificial neural network for precipitation and water level predictions of Bedup River", *International Journal of computer science*, 34(2): 10-16.
- Heckerman, D., (1997), "bayesian networks for data mining", *data mining and knowledge Discovery*, 1 (1): 79-119
- McCann, R., Marcot, B., Ellis, R., (2006), "Bayesian belief networks: application in ecology and natural resource management", *Can. J. For. Res*, 36(4) : 3053-3062
- Reggiani, P., Weerts, A., (2007), "Bayesian approach to decision-marking under uncertainty: An application to real-time forecasting in the river Rhine", *Journal of Hydrology*, 356 (2): 56-69
- Sadeghi Hesar, A., Tabatabaee, H., Jalali, M., (2012), " Monthly rainfall forecasting using Bayesian BeliefNetworks", *International Research Journal of Applied and Basic Sciences*, 3 (11): 2226-2231.
- Sreekanth, P. D., Geethanjali, N., Sreedevi, P. D., Shakeel, A., Ravi Kumar, N., Kamala Jayanthi, P. D., (2009), " Forecasting groundwater level using artificial neural networks", *Current Science*, 96 (7): 57-69.
- Steyl, G., (2009), "Application of artificial neural networks in the field of geohydrology, *Freetown, University of the Free State, South Africa*.
- Zhu, Y. M., Lu, X. X., Zhou, Y., (2007), " Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment ", *Geomorphology*, 84 (4): 111-125.