

پیش بینی LD₅₀ در مشتقات کربوکسیلیک اسید با مدل های رگرسیون خطی چندگانه و

شبکه عصبی مصنوعی

*۱ فهیمه محمایی^۱، عصمت محمدی نسب^۲

۱- دانشجوی دکتری شیمی فیزیک، گروه شیمی، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران

۲- استادیار شیمی فیزیک، گروه شیمی، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران

چکیده

در این تحقیق، از طریق مطالعه رابطه ساختار-فعالیت به پیش بینی مقادیر سمیت مشتقات کربوکسیلیک اسید پرداخته شده است. ابتدا مقادیر LD₅₀ برای مجموعه ای از ترکیبات مورد مطالعه با استفاده از منابع علمی معتبر استخراج گردید و ساختار آنها به کمک نرم افزار گوس وبو ۵۰ رسم شده و با نرم افزار گوسین ۰۹ به روش هارتی فاک و سری پایه ۲۱G-۳ بهینه شدند. سپس با استفاده از نرم افزار دراگون توصیف گرهای مولکولی استخراج گردیدند. به کمک ژنتیک الگوریتم و روش برگشتی توصیف گرهای نامناسب حذف شده و بهترین آنها برای مدل های رگرسیون خطی چندگانه و شبکه عصبی مصنوعی مورد استفاده قرار گرفت. دقت پیش بینی مدل نهایی توسط ضرایب آماری مورد بحث قرار گرفت. اعتبارسنجی نقاطعی و نیز اعتبارسنجی خارجی مدل های پیش بینی همبستگی بسیار بالا را بین مقادیر تجربی و مقادیر پیش بینی گروه های آموزش آزمون و اعتبارسنجی در روش شبکه عصبی مصنوعی نشان داد. مشخص گردید که روش شبکه عصبی مصنوعی با خطای کمتر و ضریب تعیین بالاتر نسبت به روش رگرسیون خطی چندگانه از برتری قابل توجه ای برخوردار می باشد. مدل پیشنهادی می تواند برای پیش بینی log(LD₅₀) ترکیبات جدید کربوکسیلیک اسید مفید واقع گردد.

واژه های کلیدی: "سمیت" "روش رگرسیون خطی چندگانه"؛ "شبکه عصبی مصنوعی"؛ "مشتقات کربوکسیلیک اسید" .

^{*} نویسنده رابط، پست الکترونیکی: e-mohammadinab@iau-arak.ac.ir

تاریخ دریافت مقاله: ۹۹/۱۲/۲۰ - تاریخ پذیرش مقاله: ۱۴۰۰/۲/۱۲



مقدمه

اسیدهای کربوکسیلیک از گروه های مهم اسیدهای آلی هستند که ترکیبات بسیار ارزشمندی در بدن جانوران محسوب می گردند. اسید فرمیک (جوهر مورچه)، ساده‌ترین عضو گروه اسیدهای کربوکسیلیک است که در نیش مورچه و زنبور یافت می شود و همچنین ترکیب عمده ماده گزشزا در برگ گزنه می باشد (Matysiak, et al., 2018). اسید فرمیک بیشتر به عنوان ماده نگهدارنده برای جلوگیری از فاسد شدن و آنتی باکتریال در غذای دام استفاده می شود. پاشیدن فرمیک از آن روی علف تازه خشک شده، از فساد و پوسیدگی آن جلوگیری کرده و مواد مغذی آن را تا حد بالایی حفظ مقداری از آن را می کند. برای جلوگیری از فساد غذای زمستانی دامها در مجتمع های بزرگ دامداری از این ماده استفاده می شود و در مرغداری ها به منظور از بین بردن باکتری سالمونلا به غذای مرغ اضافه می گردد. اسید فرمیک به هیدرولیز کلارن منغ های ضعیف کمک می کند و ممکن است برای تولید پیتیدهای کوچک کلارن از سایر کلارن های مهره داران مسن مورد استفاده قرار گیرد (Hong, et al., 2018). همچنین افزودن اسید استیک یا جوهر سرکه به محیط کشت سبب کاهش سرعت رشد قارچ های گیاهان می شود (Ghasemian, et al., 2018). استنشاق اسید فرمیک، استیک، پروپیونیک و بوتیریک توسط موشها باعث کاهش سریع سرعت تنفس می شود (Nielsen, 2018). آسیل هالیدها که از مشتقات کربوکسیلیک اسید هستند از واسطه های سنتزی مهم به شمار می روند، زیرا از طریق آنها می توان ترکیب های مختلفی بدست آورد (Xu, et al., 2005). یک آسیل هالید از جایگزینی هالوژن با OH- یک کربوکسیلیک اسید به دست می آید. رشد در کشاورزی و نیاز به کیفیت بهتر کالاهای کشاورزی، تقاضای کود را به دنبال دارد. این، به نوبه خود برای تقویت تولید کلریدهای اسید کربوکسیلیک پیش بینی شده است.

تاکنون تلاش زیادی جهت تعیین خواص فیزیکی-شیمیایی بسیاری از ترکیبات شیمیایی با استفاده از روش های محاسباتی، صورت گرفته است. روش های محاسباتی از قابلیت های فراوانی در بررسی و تولید ترکیبات در بدن بدون اثرات جانبی و سمیت، مطالعه ترکیباتی که از لحاظ فارماکوستیکی در سیستم های بیولوژیک پایدار هستند، طراحی منطقی مواد پر مصرف در حوزه صنایع مانند رنگ هاو مواد شیمیایی، شناسایی مواد سمی زیان آور برای محیط زیست، صرفه جویی در زمان، کاهش هزینه های مربوط به انجام آزمایش ها و پیشگویی خواص شیمیایی - فیزیکی مواد شیمیایی جدید با بازدهی بالا برخوردارند (Eriksson, 2003) یکی از این تکنیک ها، بررسی ارتباط کمی ساختار - خاصیت⁴ (QSPR) و ساختار - فعالیت⁵ (QSAR) می باشد.

(Polishchuk, 2017; Bagheban Shahri & Niazi, 2016; Mohammaei, 2018; Roy & Mitra, 2011) در این تکنیک ها، ابتدا سعی می شود که به کمک نرم افزارها و برنامه های مختلف و با استفاده از انواع توصیف گرهای مولکولی، ساختار ترکیبات با فرمول های ریاضی، به اعداد تبدیل گردد (Todeschini & Consonni, 2000; Todeschini, 2009). سپس با مدل سازی، اقدام به پیشگویی خواص و یا فعالیت ترکیبات می شود. تاکنون تحقیقات زیادی در استفاده از روش های محاسباتی برای تعیین خواص ترکیبات مختلف انجام شده است & (Ha, et al., 2019; Asadollahi-Baboli, 2018; Dehnavi, 2018; Qin, et al., 2017; Khan, et al., 2019)

نتایج یک مطالعه رابطه کمی ساختار - خاصیت در مورد سمیت ۳۵ اسیدهای کربوکسیلیک آلیفاتیک در محلول آبی نشانگر وابستگی (log IGC⁻¹₅₀) با خواصی مانند ضریب توزیع و ضریب انکسار و قطبش پذیری و دیگر خواص فیزیکی می باشد (Maguna, et al., 2003). اسیدهای کربوکسیلیک آلیفاتیک با وزن مولکولی کم که از تجزیه گیاهان، ترشحات

⁴ Quantitative Structure Property Relationship

⁵ Quantitative Structure Activity Relationship

ریشه و تجزیه مواد آلی نشات می‌گیرند، برای چندین فرآیند خاک مانند هوازدگی معدنی، شستشو و سمیت آلمینیوم و آهن، تحرک فلزات سنگین و انحلال مواد مغذی گیاه، مهم تلقی می‌شوند. (Fox & Comerford, 1990; Fox, 1995; Strobel, et al., 1999) و ضمناً می‌توانند پروتون را آزاد کنند و به عنوان لیگاند عمل نمایند و از طریق واکنشهای پیچیده ای بر حلایت و تخلخل فلز تأثیر بگذارند (Tani, et al., 1996; Slattery & Morrison, 1995). سمیت مربوط به ۳۸ اسید کربوکسیلیک آلیفاتیک با استفاده از الگوریتم ژنتیک^۶ (GA) همراه با روش حداقل مریعات جزئی^۷ (PLS) مطالعه شده و ارتباط بین $\log(\text{ICG}^{-1})_{50}$ با برخی خصوصیات مولکولی مانند ثابت تفکیک اسیدی مورد مطالعه قرار گرفته است (Kompany-Zareh., 2009). مطالعات QSAR بر روی مشتقات اسید کربوکسیلیک به عنوان مهارکننده‌های HIV-1 با استفاده از توصیفگرهای مولکولی سه بعدی با مدل‌های ماشین بردار پشتیبانی^۸ (SVM)، شبکه‌های عصبی تکثیر برگشتی^۹ (BPNN) و رگرسیون خطی چندگانه (MLR) انجام شده است. بهترین مدل QSAR نشان داده است که قطبش پذیری و جرم، موثرترین خواص اتمی تاثیرگذار روی ساختار این ترکیبات می‌باشد (Cheng, et al., 2010). تعیین فعالیت بیولوژیکی^{۱۰} ۸۶ ترکیب از مشتقات کربوکسیلیک اسید و شناسایی بهترین متغیرهای موثر بر فعالیتهای زیستی آنها با استفاده از مطالعات D-QSAR^۴ (4) به روش الگوریتم ژنتیکی کنفرورماسیون الکترونی و رگرسیون حداقل مریعات غیرخطی انجام شده است (Tuzun, et al., 2018). تجزیه و تحلیل رابطه کمی ساختار-فعالیت بر روی مشتقات اسید کربوکسیلیک ۴-کینولین انجام شده و یک مدل QSAR توصیفی از طریق محاسبه توصیفگرهای مستقل از هم با استفاده از نرم افزار MOE 2009.10 بدست آمده است. برای یک مجموعه آموزشی از ۲۰ ترکیب، تجزیه و تحلیل به روش حداقل مریعات جزئی، منجر به مدلی با مجذور ضریب همبستگی $R^2 = 0.913$ گردیده است (Hajalsiddig & Saeed., 2019).

بررسی ارتباط بین متغیرهای وابسته و مستقل در روش‌های محاسباتی و ارائه مدل‌هایی که بتواند قبل از هرگونه سنتزی، خواص ترکیبات را پیشگویی کند، برای پژوهشگران علوم تجربی از ارزش بسیار بالایی برخوردار می‌باشد.

در این مطالعه متغیرهای مستقل مورد نظر شامل توصیفگرهای مولکولی و متغیر وابسته، شاخص LD_{50}^{11} می‌باشد. LD_{50} یک معیار آماری است که شامل دوز لازم از یک ترکیب شیمیایی می‌باشد که ۵۰ درصد حیوانات تحت آزمایش را پس از ۱۴ روز می‌کشد و از آن می‌توان برای مقایسه سمیت ترکیبات شیمیایی با یکدیگر استفاده نمود، به طوری که هرچقدر مقدار LD_{50} کمتر باشد، سمیت ماده بیشتر است (Williams, 2003). ارتباط لگاریتم شاخص سمیت^{۱۲} با توصیفگرهای مولکولی در این تحقیق برای ۳۷ ترکیب از مشتقات کربوکسیلیک اسید، با کمک روش‌های محاسباتی خطی و غیرخطی، بررسی گردیده و بهترین مدل برای پیش‌بینی کمیت موردنظر ارائه گردیده است.

مواد

برای انجام این تحقیق، تعداد ۳۷ ترکیب از مشتقات کربوکسیلیک اسید با استفاده از وب‌سایت سیگما الدرج (Sigma Aldrich) شناسایی و مقادیر تجربی شاخص سمیت ($\text{LD}_{50}^{13} \text{mg.kg}^{-1}$) برای همه ترکیبات، با استفاده از منبع معتبر علمی (chemidplus) در جدول ۱ مندرج گردیدند.

⁶ Genetic Algorithm

⁷ Partial least squares regression

⁸ Support Vector Machine

⁹ Back propagation neural network

¹⁰ Lethal Dose, which causes the death of 50% (one half) of a group of test animals

جدول ۱- نام، ساختار و مقادیر LD₅₀ مشتقات کربوکسیلیک اسید مورد مطالعه

Table 1- The name, chemical structure and LD₅₀ values of studied carboxylic acids derivatives.

| No | Compound | LD ₅₀ (mg.kg ⁻¹) | Structure |
|----|-------------------------------|--|-----------|
| 1 | Trichloroacetyl chloride | 600 | |
| 2 | Dichloroacetyl chloride | 2,460 | |
| 3 | Bromoacetyl chloride | 3,200 | |
| 4 | Chloroacetyl chloride | 208 | |
| 5 | Acetyl chloride reagent | 910 | |
| 6 | Methyl chloroformate | 60 | |
| 7 | 2,3-Dibromopropionyl chloride | 1,200 | |
| 8 | 2-Chloropropionyl chloride | 642 | |
| 9 | 3-Chloropropionyl chloride | 1,200 | |
| 10 | 1-Chloroethyl chloroformate | 470 | |
| 11 | 2-Chloroethyl chloroformate | 859 | |
| 12 | Propionyl chloride | 823 | |
| 13 | Ethyl chloroformate | 270 | |
| 14 | 4-Chlorobutyryl chloride | 1,350 | |
| 15 | Butyryl chloride | 785 | |
| 16 | Propyl chloroformate | 1,045 | |
| 17 | Glutaryl chloride | 190 | |
| 18 | Trimethylacetyl chloride | 638 | |
| 19 | Chloroacetic acid | 76 | |
| 20 | 2-Chloropropanoic acid | 800 | |

| | | | |
|----|--------------------------|-------|--|
| 21 | 6-Chlorohexanoic acid | 3,080 | |
| 22 | Phenyl chloroformate | 1,410 | |
| 23 | m-Toluoyl chloride | 3,440 | |
| 24 | 2-Ethylhexanoyl chloride | 1,500 | |
| 25 | methanoic acid | 1,100 | |
| 26 | ethanoic acid | 3,310 | |
| 27 | Oxalic acid | 7,500 | |
| 28 | Glyoxylic acid | 3,000 | |
| 29 | Acrylic acid | 2,500 | |
| 30 | Malonic acid | 100 | |
| 31 | propanedioic acid | 1,310 | |
| 32 | 2-hydroxypropanoic acid | 3,543 | |
| 33 | 1-hydroxypropanoic acid | 2,937 | |
| 34 | butanoic acid | 2,940 | |
| 35 | 2-methylpropanoic | 280 | |
| 36 | pentanoic acid | 9,300 | |
| 37 | Ethyl propionate | 7,500 | |

لازم به ذکر است که همه مقادیر مندرج شده در این مطالعه مربوط به شاخص سمیت تجویز دهانی LD₅₀ می‌باشند که به دلیل پراکنده‌گی مقادیر آنها، برای انجام محاسبات، مقادیر لگاریتمی آن‌ها به کار گرفته شده‌اند.

روش کار

پس از جمع‌آوری ترکیبات و داده‌ها، با استفاده از نرم‌افزار گوس ویو¹¹ ساختار اولیه^{۳۷} ترکیب مورد مطالعه ترسیم گردیده و بهینه سازی آنها بوسیله نرم‌افزار گوسین^{۱۲} به روشن^{۱۳} HF با سری پایه 3-21G انجام گردید. نرم‌افزار دراگون^{۱۴} بهمنظور محاسبه انواع توصیف‌گرهای مولکولی به کار گرفته شد و بهمنظور غربالگری شاخص‌های بهدست آمده، از برنامه متلب^{۱۵} و الگوریتم ژنتیک (Mirjalili, et al., 2019; Mirjalili, et al., 2020) با روش برگشتی استفاده شد (Elisseeff & Guyo, 2003). الگوریتم ژنتیک، یک روش جستجوی هوشمند و تصادفی است که با بهکارگیری عملگرهای ژنتیک از یک فرایند تکامل تدریجی تبعیت می‌کند. پس از حذف توصیف‌کننده‌های غیرضروری، آن‌هایی که بیشترین میزان همبستگی را با لگاریتم LD₅₀ داشتند برای مدل سازی با روش‌های ANN و MLR انتخاب شدند (Kutner et al., 2004). در روش‌های رگرسیون خطی چندگانه^{۱۶} (MLR) و غیرخطی^{۱۷} (NLR) که در این مدل‌سازی‌ها استفاده می‌شوند، خواص و یا فعالیت به عنوان متغیر وابسته و توصیف‌گرهای مولکولی به عنوان متغیرهای مستقل در نظر گرفته می‌شوند (Goodarzi, et al., 2012; Randic & Basak, 2000). در موقعي که الگوی ساده خطی، ارائه‌دهنده مدل مناسبی برای رسیدن به هدف نیست، روش‌های غیرخطی بکار گرفته می‌شوند (Fissa, et al., 2019; Roy & Ambure., 2016). روش شبکه عصبی مصنوعی^{۱۸} ANN که به عنوان یکی از روش‌هایی که به بررسی ارتباط غیرخطی بین متغیرهای مستقل با متغیر وابسته می‌پردازد، کاربرد گسترده‌ای در حیطه مطالعات ارتباط ساختار-فعالیت دارد (Cross, et al., 1995). روش شبکه عصبی مصنوعی ANN بر اساس نورون‌های عصبی پایه‌گذاری شده و توانایی این را دارد که روش‌های آماری کلاسیک و مدرن را با هم ترکیب کند (Haykin, 1990). در یک شبکه عصبی مصنوعی، برای ایجاد ارتباط بین متغیرهای مستقل و وابسته از لایه‌هایی استفاده می‌شود که این لایه‌ها با یکدیگر در ارتباط هستند و شامل لایه ورودی، لایه خروجی و لایه‌های پنهان یا میانی است. لایه‌های پنهان به این دلیل استفاده می‌شوند که بر ارائه مدل نهایی تأثیرگذار هستند و دلیل بکار بردن یک لایه خروجی به خاطر ارائه یک نتیجه منطقی برای پیش‌بینی خاصیت موردنظر می‌باشد (Gadzuric et al., 2015; Miller & Miller, 2010; Maiellaro et al., 2004).

نتایج و بحث

پس از رسم و بهینه‌سازی ترکیبات مورد مطالعه با نرم‌افزار گوسین، فایل‌های خروجی حاصل از محاسبات کوانتومی برای همه ترکیبات مورد مطالعه، به برنامه دراگون انتقال داده شد تا به محاسبه توصیف‌گرهای مولکولی پرداخته شود. در نتیجه این محاسبات، ۱۸۵۱ توصیف‌گر مولکولی در ۱۸ گروه مختلف بدست آمد. لذا برای تعیین مناسبترین توصیف‌گرها از روش الگوریتم ژنتیک برنامه متلب 2010a و روش برگشتی استفاده گردید. از این تعداد توصیف‌گر اولیه با حذف

¹¹ Gauss View 05

¹² Gaussian 09

¹³ Hartree fock

¹⁴ Dragon

¹⁵ MATLAB 2010a

¹⁶ Multiple linear regression

¹⁷ Nonlinear regression

¹⁸ Artificial Neural Network

شاخص‌های غیرضروری و توصیف کننده‌های نامناسب، آنها برای انتخاب شدند که بیشترین میزان همبستگی را با Log LD₅₀ برقرار نموده ولی کمترین میزان همبستگی را با توصیفگرهای دیگر داشتند. بنابر این مشخص گردید که تعداد توصیف‌گرهای نهایی برای مدل‌سازی ۱۹ شاخص می‌باشد. این توصیف‌گرهای در جدول ۲ ارائه شده‌اند، برای مشخص شدن الگوی بهتر در روش رگرسیون خطی مورد استفاده قرار گرفتند.

تجزیه و تحلیل در روش خطی

جهت انجام محاسبات در مدل خطی، ترکیبات به دو دسته آموزش و آزمون (به نسبت ۸۰٪ و ۲۰٪) تقسیم شدند. پارامترهای اعتبارسنجی مربوط به آنالیز ترکیبات آموزش که شامل ضریب تعیین^{۱۹} R²، ضریب همبستگی^{۲۰} R و ضریب تعیین تعدیل یافته^{۲۱} R²_{adj} و آماره فیشر^{۲۲} F و سطح معناداری^{۲۳} Sig و خطای مربعات میانگین^{۲۴} (MSE) و جذر خطای میانگین مربعات^{۲۵} (RMSE) می‌باشند در جدول (۲) آورده شده‌اند.

جدول ۲ توصیف‌گرهای و ضرایب آماری به دست آمده مربوط به log LD₅₀

Table 2- List of descriptors and statistical coefficients

| Model | Independent variables | R | R ² | R ² _{adj} | RMSE | F | Sig |
|-------|---|-------|----------------|-------------------------------|-------|-------|-------|
| 1 | Mor13m, IVDE, Mor06u, EEig01r, DISPv, RDF020u, Mor32u, MAXDN, Mor02m, DISPe, Mor09m, TIE, ESPm03d, Mor07m, BEHv4, RDF020v, ATS2p, DISPp, MA | 0.827 | 0.684 | 0.33 | 0.439 | 1.934 | 0.08 |
| 2 | Mor13m, IVDE, Mor06u, EEig01r, DISPv, RDF020u, MAXDN, Mor02m, DISPe, Mor09m, TIE, ESPm03d, Mor07m, BEHv4, RDF020v, ATS2p, DISPp, MAXDP | 0.827 | 0.684 | 0.367 | 0.427 | 2.161 | 0.056 |
| 3 | Mor13m, IVDE, Mor06u, EEig01r, DISPv, RDF020u, MAXDN, DISPe, Mor09m, TIE, ESPm03d, Mor07m, BEHv4, RDF020v, ATS2p, DISPp, MAXDP | 0.827 | 0.683 | 0.4 | 0.416 | 2.409 | 0.033 |
| 4 | Mor13m, IVDE, EEig01r, DISPv, RDF020u, MAXDN, DISPe, Mor09m, TIE, ESPm03d, Mor07m, BEHv4, RDF020v, ATS2p, DISPp, MAXDP | 0.826 | 0.682 | 0.428 | 0.406 | 2.681 | 0.019 |
| 5 | Mor13m, IVDE, EEig01r, DISPv, MAXDN, DISPe, Mor09m, TIE, ESPm03d, Mor07m, BEHv4, RDF020v, ATS2p, DISPp, MAXDP | 0.825 | 0.681 | 0.453 | 0.397 | 2.991 | 0.011 |
| 6 | Mor13m, IVDE, EEig01r, DISPv, MAXDN, DISPe, Mor09m, TIE, ESPm03d, Mor07m, RDF020v, ATS2p, DISPp, MAXDP | 0.823 | 0.677 | 0.472 | 0.390 | 3.295 | 0.006 |
| 7 | Mor13m, IVDE, EEig01r, DISPv, MAXDN, DISPe, Mor09m, TIE, ESPm03d, Mor07m, RDF020v, DISPp, MAXDP | 0.819 | 0.671 | 0.484 | 0.385 | 3.602 | 0.004 |
| 8 | Mor13m, IVDE, EEig01r, DISPv, MAXDN, DISPe, TIE, ESPm03d, Mor07m, RDF020v, DISPp, MAXDP | 0.814 | 0.663 | 0.494 | 0.381 | 3.935 | 0.002 |
| 9 | IVDE, EEig01r, DISPv, MAXDN, DISPe, TIE, ESPm03d, Mor07m, RDF020v, DISPp, MAXDP | 0.805 | 0.648 | 0.493 | 0.382 | 4.182 | 0.001 |
| 10 |), IVDE, EEig01r, MAXDN, DISPe, TIE, ESPm03d, Mor07m, RDF020v, DISPp, MAXDP | 0.786 | 0.617 | 0.470 | 0.390 | 4.195 | 0.002 |
| 11 | IVDE, EEig01r, MAXDN, TIE, ESPm03d, Mor07m, RDF020v, DISPp, MAXDP | 0.765 | 0.585 | 0.446 | 0.399 | 4.223 | 0.002 |
| 12 | IVDE, MAXDN, TIE, ESPm03d, Mor07m, RDF020v, DISPp, MAXDP | 0.752 | 0.565 | 0.441 | 0.401 | 4.552 | 0.001 |
| 13 | IVDE, MAXDN, ESPm03d, Mor07m, RDF020v, DISPp, MAXDP | 0.743 | 0.552 | 0.444 | 0.400 | 5.111 | 0.001 |
| 14 | IVDE, MAXDN, ESPm03d, RDF020v, DISPp, MAXDP | 0.731 | 0.534 | 0.441 | 0.401 | 5.729 | 0.000 |

¹⁹Coefficient of determination

²⁰Correlation coefficient

²¹R²_{adjusted}

²²Fisher

²³Significance level

²⁴Mean Squared Error

²⁵Root Mean Squared Error

مقادیر مختلف ضرایب آماری در جدول ۲ برای مدل‌های مختلف نشان داده شده است. با توجه به اینکه یکی از شرایط معادله مناسب وجود تعداد توصیف گر کمتر می‌باشد، لذا مدل‌های با ضریب رگرسیون $R^2 = 0.68$ که ضرایب آماری نسبتاً نزدیک به هم دارند در صورتی می‌توانند (تا حدودی) مورد قبول واقع گردند که حاوی تعداد توصیف گر کمتری باشند. معادله ارتباط نهایی بدست آمده (با توجه به ضریب فیشر بالاتر، خطای کمتر و تعداد توصیف گر کمتر) بین log LD₅₀ و توصیفگرهای نهایی IVDE، MAXDN، ESpm03d، RDF020v، DISPp، MAXDP^{۳۷} برای ۳۷ ترکیب مورد مطالعه به همراه ضریب رگرسیون R، ضریب تعیین R^2 ، ضریب رگرسیون تعدیل شده R^2_{adj} ، خطای جذر میانگین مربعات RMSE، سطح معناداری Sig، آماره دوربین-واتسون^{۲۶} D-W، به صورت زیر بدست آمده است:

$$\text{Log LD}_{50} = 5.011 + 0.654 \text{ (MAXDN)} + 0.888 \text{ (MAXDP)} - 1.158 \text{ (IVDE)} - 1.076 \text{ (ESpm03d)} - 0.576 \text{ (DISPp)} + 0.423 \text{ (RDF020v)}$$

N=37, R=0.731, $R^2=0.534$, $R^2_{adj}=0.441$, Durbin-Watson= 1.998, RMSE=0.401, F=5.729, Sig=0.000

مقدار ضریب رگرسیون $R=0.731$ در مدل آخر، میزان ارتباط خطی بین log LD₅₀ و متغیرهای مستقل را بیان می‌کند. مقدار بدست آمده برای ضریب تعیین نشان می‌دهد که فقط ۵۳٪ تغییرات log LD₅₀ بهوسیله توصیف گرهای وابسته به آن تبیین می‌شوند. R^2_{adj} مقدار ضریب تعیین را با توجه به متغیرهای مستقل اضافه شده به خط رگرسیون و با توجه به عرض از مبدأهای جدید، تعدیل و اصلاح می‌کند. مقدار محاسبه شده برای RMSE بیانگر خطای جذر میانگین مربعات است. مقدار سطح معنی‌داری برابر با صفر، حاکی از معنادار بودن رابطه فوق می‌باشد. مقدار بهینه برای آماره D-W در بازه بین ۰ تا ۴ می‌باشد و مقدار D-W=1.998 برای داده‌های آموزش، نشان دهنده عدم خودهمبستگی میان باقیمانده‌هاست.

تجزیه و تحلیل در روش غیر خطی

با توجه به پایین بودن مقادیر رگرسیون و مقدار نسبتاً بالای خطای میانگین در مدل ارائه شده به روش خطی، به مطالعه ارتباط کمی ساختار - فعالیت به روش غیرخطی، اقدام گردید. برای مدل سازی در روش غیرخطی، ۶ توصیف گر بدست آمده در مدل خطی نهایی، به کار گرفته شده اند. به منظور بررسی همبستگی بین توصیف گرهای، بایستی ضرایب همبستگی پیرسون^{۲۷} (PCC) و ضرایب نفوذپذیری^{۲۸} VIF محاسبه شوند که مقادیر آنها برای توصیف گرهای مدل نهایی در جدول ۳ آورده شده اند. هرچه مقدار PCC بین توصیف گرها کمتر از یک و مقدار VIF بین ۱ تا ۱۰ باشد، می‌توان نتیجه گرفت بین متغیرهای مستقل مورد بررسی همبستگی وجود ندارد و یا این همبستگی کم می‌باشد. اگر دو متغیر مستقل دارای همبستگی باشند باید یکی از آن‌ها حذف گردد (عمولاً شاخصی که بالاترین PCC و VIF را دارد حذف می‌شود). در نهایت مدلی که دارای حداقل همبستگی بین توصیفگرهای و کمترین مقدار ضریب نفوذپذیری باشد به عنوان بهترین مدل انتخاب می‌گردد.

²⁶ Durbin-Watson

²⁷ Pearson's correlation coefficient

²⁸ Variance inflation factor

جدول ۳ ماتریس همبستگی و ضرایب نفوذپذیری بین توصیفگرهای مولکولی در مدل نهایی^{۵۰}

Table 3- The correlation matrix between the molecular descriptors and permeability coefficients in final model

| Descriptor | IVDE | MAXDN | ESpm03d | RDF020v | DISPp | MAXDP | Tolerance | VIF |
|------------|--------|--------|---------|---------|-------|-------|-----------|-------|
| IVDE | 1.000 | | | | | | 0.764 | 1.309 |
| MAXDN | -0.053 | 1.000 | | | | | 0.390 | 2.564 |
| ESpm03d | 0.162 | -0.060 | 1.000 | | | | 0.452 | 2.213 |
| RDF020v | -0.107 | 0.446 | -0.252 | 1.000 | | | 0.643 | 1.556 |
| DISPp | 0.070 | 0.348 | -0.242 | 0.034 | 1.000 | | 0.805 | 1.243 |
| MAXDP | -0.381 | 0.545 | -0.066 | 0.03 | 0.077 | 1.000 | 0.357 | 2.798 |

با توجه به نتایج درج شده در جدول ۳ معلوم می‌گردد که توصیفگرهای هندسی^{۲۹}، ساختاری^{۳۰}، اطلاعاتی^{۳۱} و مجاورت^{۳۲} نسبت به دیگر توصیفگرهای مولکولی از اهمیت بیشتری برای مدلسازی سمیت مشتقان کربوکسیلیک اسید برخوردار می‌باشند. تعریف و نوع شش توصیف گر نهایی در جدول ۴ شرح داده شده است.

جدول ۴ شرح و نوع توصیف گرهای نهایی

Table 4- Description and type of final descriptors

| Notation | Descriptor | Type of Descriptor |
|----------|---|------------------------|
| IVDE | mean information content on the vertex degree equality | Information index |
| MAXDN | mean information content on the vertex degree equality | Information index |
| MAXDP | maximal electrotopological negative variation | Topological index |
| ESpm03d | Spectral moment 01 from edge adj. matrix weighted by dipole moments | Edge adjacency index |
| DISPp | displacement value / weighted by polarizability | Geometrical descriptor |
| RDF020v | maximal electrotopological positive variation | Topological index |

در مدل سازی به روش ANN کل ترکیبات به صورت تصادفی به دسته آموزشی، آزمون و اعتبارسنجی به نسبت های ۷۰٪ و ۱۵٪ تقسیم بندی شدند، بطوری که برای نمونه آزمایشی ۲۵ ترکیب و برای نمونه های آزمون و ارزیابی هر یک ۶ ترکیب در نظر گرفته شد و سپس اقدام به مدلسازی گردید و ضرایب آماری برای هر یک به تفکیک محاسبه گردیدند.

ارزیابی مدل به دست آمده در روش ANN برای پیش‌بینی $\log LD_{50}$ در جدول ۵ تعداد ترکیبات بکار گرفته شده و نیز مقادیر RMSE، MSE، R^2 بدست آمده در بهترین مدل برگزیده با استفاده از روش ANN برای سه دسته آموزش، آزمون و اعتبارسنجی ارائه شده است.

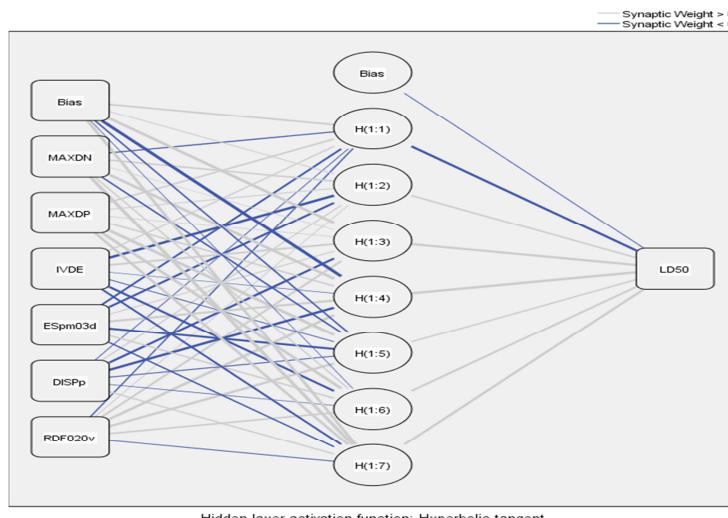
²⁹ Geometrical
³⁰ Topological
³¹ Information
³² Edge adjacency

جدول ۵ نتایج مدل سازی برای $\log \text{LD}_{50}$ در مجموعه آزمایشی و آزمون و ارزیابی در روش شبکه عصبی مصنوعی

Table-5: The modelling results in train, test and validation sets in ANN method.

| parameters | sample | MSE | RMSE | R | R^2 |
|------------|--------|---------|---------|---------|---------|
| Train | 25 | 0.00183 | 0.04278 | 0.97482 | 0.95027 |
| validation | 6 | 0.02996 | 0.17309 | 0.99584 | 0.99169 |
| test | 6 | 0.02543 | 0.15948 | 0.99425 | 0.98854 |

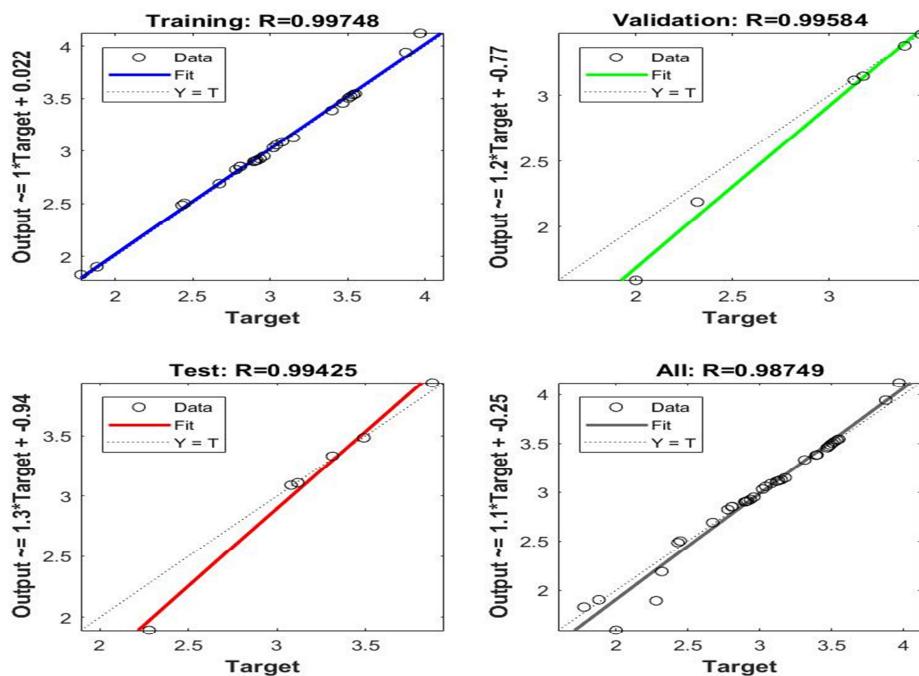
تعداد شاخص های ورودی که در شبکه عصبی به نام لایه های ورودی شناخته می شود، همان ۶ توصیف گر مولکولی مستخرج از مدل نهایی در روش MLR می باشند. تعداد لایه پنهان که برنامه محاسباتی آن را لحاظ کرده است، بعد از انجام عملیات بهینه سازی و تکرار زیاد برای درج بهترین نتیجه، شش لایه و نیز تعداد لایه خروجی نیز یک لایه می باشد. شکل ۱ ساختار ANN به کار برده شده در مدل غیر خطی را نشان می دهد.



شکل ۱ ساختار ANN برای $\log \text{LD}_{50}$

Fig 1 Structure of artificial neural network

نمودار مقادیر تجربی $\log \text{LD}_{50}$ بر حسب مقادیر پیش بینی LD_{50} در روش ANN برای هر سه دسته آموزش، آزمون و اعتبارسنجی ترکیبات مورد مطالعه در شکل ۲ نشان داده شده است.

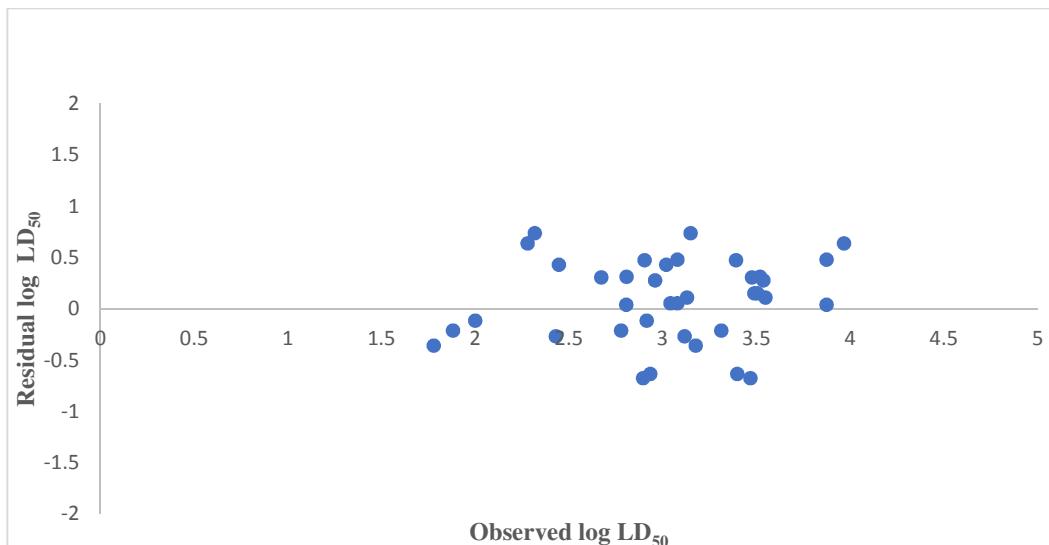


شکل ۲ نمودار مقادیر مشاهده شده در مقابل مقادیر پیش بینی شده $\log LD_{50}$ با روش ANN

برای کل داده ها و دسته های آموزش، آزمون و اعتبارسنجی

Fig 2 The curves of $\log LD_{50}$ observed versus predicted values for all, train, test and validation sets

همچنین در شکل ۳ نمودار تغییرات مقادیر مشاهده شده بر حسب باقیمانده برای لگاریتم سمتیت با روش ANN نشان داده شده است.



شکل ۳- نمودار تغییرات مقادیر تجربی $\log LD_{50}$ بر حسب مقادیر باقیمانده در روش ANN

Fig 3 The curve of $\log LD_{50(\text{exp})}$ versus $\log LD_{50(\text{res})}$ values in ANN method

تجزیه و تحلیل با استفاده از روش ANN

مقادیر نسبتاً بالای R برای هر سه دسته و همچنین مقدار خطای کم RMSE در آنها برتری روش شبکه عصبی مصنوعی نسبت به روش خطی چندگانه برای پیش‌بینی لگاریتم شاخص سمیت LD₅₀ تأیید می‌گردد. ضریب رگرسیون R () بالای ۹۷ درصد بیانگر میزان ارتباط خطی بالا بین مقادیر LD₅₀ و توصیف گرهای مولکولی می‌باشد. با توجه به مقادیر RMSE=0.04278867 و $R^2 = 0.95274$, معلوم می‌شود که بیش از ۹۵٪ از تغییرات شاخص سمیت LD₅₀ در ترکیبات آموزش را می‌توان توسط توصیف گرهای مولکولی فوق تبیین نمود. میزان پراکنده‌گی نقاط برای سه دسته آموزش و آزمون و اعتبار سنجی در نمودار مشاهده شده برحسب پیش‌بینی شده حاکی از همبستگی خوب بین توصیف گرهای نهایی با لگاریتم سمیت و درنتیجه کار آئی روش به کار رفته در پیش‌بینی مشتقات کربوکسیلیک اسید می‌باشد. همچنین نمودار تغییرات مقادیر مشاهده شده برحسب باقیمانده نشان می‌دهد که خطاهای در اطراف محور x توزیع یکسانی دارند و این نمایانگر این است که الگوی مذکور برای پیش‌بینی log LD₅₀ در ترکیبات مورد مطالعه از دقت بالا و بسیار خوبی برخوردار می‌باشد.

مقادیر تجربی پیش‌بینی و باقیمانده مربوط به لگاریتم شاخص LD₅₀ در روش ANN مطابق جدول ۶ گزارش شده است.

جدول ۶ مقادیر مشاهده شده، پیش‌بینی شده و باقیمانده log LD₅₀ برای مشتقات کربوکسیلیک اسید در مدل‌های MLR و ANNTable 6The log LD₅₀ observed, predicted and residual values of carboxylic acids derivatives in MLR and ANN

| No | log LD _{50(obs)} | MLR | ANN | |
|----|----------------------------|---------------------------|----------------------------|---------------------------|
| | log LD _{50(Pred)} | log LD _{50(Res)} | log LD _{50(Pred)} | log LD _{50(Res)} |
| 1 | 2.778 | 3.094 | -0.316 | 2.951 |
| 2 | 3.391 | 3.080 | 0.310 | 3.132 |
| 3 | 3.505 | 3.054 | 0.450 | 2.882 |
| 4 | 2.318 | 2.754 | -0.433 | 2.931 |
| 5 | 2.959 | 2.843 | 0.111 | 2.889 |
| 6 | 1.778 | 2.326 | -0.548 | 2.638 |
| 7 | 3.079 | 3.370 | -0.291 | 2.740 |
| 8 | 2.808 | 2.731 | 0.077 | 2.723 |
| 9 | 3.079 | 2.799 | 0.279 | 2.869 |
| 10 | 2.672 | 2.443 | 0.228 | 2.649 |
| 11 | 2.934 | 2.826 | 0.107 | 2.949 |
| 12 | 2.915 | 2.460 | 0.455 | 2.503 |
| 13 | 2.431 | 2.397 | 0.033 | 2.553 |
| 14 | 3.130 | 3.127 | 0.002 | 3.082 |
| 15 | 2.895 | 2.580 | 0.315 | 2.505 |
| 16 | 3.019 | 2.569 | 0.449 | 2.623 |
| 17 | 2.279 | 2.782 | -0.503 | 3.214 |
| 18 | 2.805 | 3.045 | -0.240 | 2.937 |
| 19 | 1.881 | 2.477 | -0.597 | 2.541 |
| 20 | 2.903 | 3.237 | -0.334 | 3.116 |
| 21 | 3.489 | 3.320 | 0.168 | 3.016 |
| 22 | 3.149 | 3.222 | -0.073 | 2.998 |
| 23 | 3.537 | 3.239 | 0.297 | 2.801 |
| 24 | 3.176 | 3.367 | -0.191 | 2.901 |
| 25 | 3.041 | 3.226 | -0.185 | 3.402 |
| 26 | 3.520 | 3.477 | 0.042 | 3.465 |
| 27 | 3.875 | 3.529 | 0.345 | 3.563 |
| 28 | 3.477 | 2.755 | 0.721 | 3.000 |
| 29 | 3.398 | 3.286 | 0.111 | 3.094 |
| 30 | 2.000 | 2.690 | -0.690 | 2.636 |
| 31 | 3.117 | 2.802 | 0.314 | 3.235 |
| 32 | 3.549 | 3.838 | -0.289 | 3.818 |
| 33 | 3.468 | 3.298 | 0.169 | 3.359 |
| 34 | 2.447 | 3.248 | -0.801 | 3.125 |
| 35 | 3.968 | 3.761 | 0.206 | 3.540 |
| 36 | 3.875 | 3.455 | 0.419 | 3.238 |
| 37 | 3.312 | 3.434 | -0.122 | 3.272 |

مقایسه روش‌های رگرسیون خطی با شبکه عصبی، نشان داد که بین مقادیر سمیت مشتقات کربوکسیلیک اسیدها با توصیفگرهای مولکولی، رابطه غیرخطی وجود دارد. مدل رگرسیون خطی بکار گرفته شده، علی‌رغم اینکه چارچوب وسیعی را در بر می‌گیرد که با تحلیل‌های زیادی همراه است، ولی نمی‌تواند الگوی مناسبی برای هدف این تحقیق باشد، زیرا در بعضی مواقع، متغیرهای رگرسیونی با توابع غیرخطی به هم مربوط می‌شوند. بنابر این، شبکه عصبی مصنوعی به عنوان یک مدل غیرخطی، می‌تواند روابط غیرخطی پیچیده یا لاشهای پنهان بین متغیرهای وابسته و مستقل را بیابد و با دقت بهتری نسبت به روش‌های رگرسیونی خطی عمل نماید. روش ANN رابطه خوب بین ورودی و خروجی ایجاد نموده و از حساسیت کمتری نسبت به وجود خطاهای در اطلاعات ورودی برخوردار است، لذا از نظر میزان توانایی در پیش‌بینی ارتباط بین متغیر وابسته و متغیرهای مستقل و قابلیت تعمیم نسبت به روش‌های دیگر مدل‌سازی، نتیجه قابل قبول‌تری ارائه داده است.

نتیجه گیری

بسیاری از کربوکسیلیک اسیدها، سمی و برای سلامتی بشر مضرند. بسیاری از آنها موادی خورنده و در صورت تماس با پوست باعث سوختگی شیمیایی می‌گردند و تنفس بخارات آن‌ها موجب تحریک و سوزش دستگاه تنفسی می‌شود. اندازه‌گیری سمیت بسیاری از مشتقات کربوکسیلیک اسید از طریق روش‌های آزمایشگاهی به دلایل ذکر شده زیان‌آور می‌باشد. به کارگیری روش‌های محاسباتی هم باعث صرفه جویی در وقت و هزینه های آزمایشگاهی می‌شود و هم سبب آسیب نرسیدن به محیط زیست برای ترکیبات شناخته شده و یا فاقد اطلاعات لازم می‌گردد. به همین منظور در این تحقیق، با مطالعه رابطه ساختار-فعالیت به پیش‌بینی مقادیر لگاریتم سمیت LD₅₀ کربوکسیلیک اسیدها با دقت بالا پرداخته شده است. از بین تعداد بسیار زیاد توصیف گرهای مولکولی محاسبه شده با روش الگوریتم ژنتیک و برگشتی، معلوم گردید که هفت توصیف گر از گروه‌های هندسی، ساختاری، مجاورت و اطلاعاتی نسبت به دیگر توصیف گرهای مولکولی از اهمیت بالاتری برخوردار هستند. به منظور مطالعه رابطه ساختار-فعالیت، برای ترکیبات مورد مطالعه از هر دو مدل رگرسیون خطی چندگانه MLR و نیز شبکه عصبی مصنوعی ANN استفاده گردیده است. پارامترهای آماری در مدل نهایی برتری قابل توجه مدل ANN را نسبت به مدل MLR، برای پیش‌گویی لگاریتم سمیت ترکیبات مورد مطالعه نشان دادند. نتایج این تحقیق نشان داد که می‌توان گام‌های بلندی را جهت پیش‌بینی مقادیر سمیت بسیاری از مشتقات جدید کربوکسیلیک اسید با تکیه بر مدل‌های محاسباتی به کمک پارامترهای اعتبارسنجی مناسب برداشت. بدیهی است که چنین مدلی قطعاً به منظور شناخت بیشتر ویژگی‌های این دسته از ترکیبات شیمیایی و حتی کاربرد آنها در طراحی ترکیبات شیمیایی و صنعتی بسیار مفید خواهد بود.

Reference

- Asadollahi-Baboli, M. and Dehnavi, S. 2018.** Docking and QSAR analysis of tetracyclic oxindole derivatives as α -glucosidase inhibitors. Computational biology and chemistry, 76: 283-292.
- Bagheban Shahri, F. and Niazi, A. 2016.** Quantitative structure activity relationship study of inhibitory activities of 5-lipoxygenase and design new compounds by different chemometrics methods. Iranian Journal of mathematical Chemistry, 7: 47-59.
- Cheng, Z., Zhang, Y. and Fu, W. 2010.** QSAR study of carboxylic acid derivatives as HIV-1 Integrase inhibitors. European journal of medicinal chemistry, 45(9): 3970-3980.
- Cross, S., Harrison, R. F., Kennedy, R. L. 1995.** Introduction to neural networks, Lancet, 346: 1075-9.

- Elisseeff, A. and Guyon, I. 2003.** An introduction to variable and feature selection. *J. of Machine Learning Research*, 19: 1157-1182.
- Eriksson, L., Jaworska, J., Worth, A. P., Cronin, M. T D., McDowell, R. M. and Gramatica, P. 2003.** Methods for reliability and uncertainty assessment and for applicability evaluations of classification-and regression-based QSARs. *Environ Health Perspect*. 111(10): 1361–1375.
- Fissa, M.R., Lahiouel, Y., Khaouane, L. and Hanini, S. 2019.** QSPR estimation models of normal boiling point and relative liquid density of pure hydrocarbons using MLR and MLP-ANN methods. *Journal of Molecular Graphics and Modelling*, 87: 109-120.
- Fox, T.R. and Comerford, N.B. 1990.** Low-molecular-weight organic acids in selected forest soils of the southeastern USA. *Soil Science Society of America Journal*, 54(4): 1139-1144.
- Fox, T.R. 1995.** The influence of low-molecular-weight organic acids on properties and processes in forest soils. *Carbon forms and functions in forest soils*, pp:43-62.
- Gadzuric, S. B., Podunavac-Kuzmanovic, S. O., Jokic, A. I., Vranes, M. B., Ajdukovic, N and Kovacevic, S. Z. 2015.** Chemometric estimation of post-mortem interval based on Na⁺ and K⁺ concentrations from human vitreous humour by linear least squares and artificial neural network. *Australian Journal of Forensic Sciences*, 46: 166-179.
- Ghamali, M., Chtita, S., Ousaa, A., Elidrissi, B., Bouachrine, M. and Lakhifi, T. 2017.** QSAR analysis of the toxicity of phenols and thiophenols using MLR and ANN. *Journal of Taibah University for Science*, 11(1): 1-10.
- Ghasemian, A., Asadollahzadeh, M., Saraeian, A., Resalati, H. and Taherzadeh, M. 2018.** Effect of Acetic Acid on Growth and Ethanol Fermentation of Filamentous Fungi Rhizopus oryzae, Mucor indicus, Neurospora intermedia and Aspergillus oryzae. *Experimental animal Biology*, 7(3): 119-130.
- Goodarzi, M., Dejaegher, B. and Heyden, Y. V. 2012.** Feature selection methods in QSAR studies. *Journal of AOAC International*, 95(3): 636-651.
- Ha, H., Park, K., Kang, G. and Lee, S. 2019.** QSAR study using acute toxicity of Daphnia magna and Hyalella azteca through exposure to polycyclic aromatic hydrocarbons (PAHs). *Ecotoxicology*, 28(3): 333-342.
- Hajalsiddig, T.T.H. and Saeed, A.E.M. 2019.** QSAR and molecular docking studies on 4-quinoline carboxylic acid derivatives as inhibition of vesicular stomatitis virus replication. *European Journal of Chemistry*, 10(1): 45-51.
- Haykin, S. 1990.** Neural networks -a comprehensive foundation, 2nd ed. New Jersey: Prentice-Hall.
- Hong, H., Roy, B.C., Chalamaiyah, M., Bruce, H.L. and Wu, J. 2018.** Pretreatment with formic acid enhances the production of small peptides from highly cross-linked collagen of spent hens. *Food chemistry*, 258: 174-180.
- Khan, K., Benfenati, E. and Roy, K. 2019.** Consensus QSAR modeling of toxicity of pharmaceuticals to different aquatic organisms: ranking and prioritization of the DrugBank database compounds. *Ecotoxicology and environmental safety*, 168: 287-297.
- Kompany-Zareh, M. 2009. An improved QSPR study of the toxicity of aliphatic carboxylic acids using genetic algorithm. *Medicinal chemistry research*, 18(2): 143-157.
- Kutner, M. K., Nachtsheim, C. J. and Neter, J. 2004.** Applied linear regression models, Boston: McGraw-Hill.
- Maguna, F.P., Ninez, M.B., Okulik, N.B. and Castro, E.A. 2003.** Improved QSAR analysis of the toxicity of aliphatic carboxylic acids. *Russian Journal of General Chemistry*, 73(11): 1792-1798.
- Maiellaro, P. A., Cozzolongo, R. and Marino, P. 2004.** Artificial neural networks for the prediction of response to interferon plus ribavirin treatment in patients with chronic hepatitis C. *Cuurent Pharmaceutical Design*, 10: 2101-2109.
- Matysiak, I., Balcerzak, M. and Michalski, R. 2018.** Ion chromatography with conductometric detection for quantitation of formic acid in Polish bee honey. *Journal of Food Composition and Analysis*, 73: 55-59.

- Mirjalili, S. 2019.** Genetic algorithm. In Evolutionary algorithms and neural networks, pp: 43-55. Springer, Cham.
- Mirjalili, S., Dong, J.S., Sadiq, A.S. and Faris, H. 2020.** Genetic algorithm: Theory, literature review, and application in image reconstruction. Nature-inspired optimizers, pp: 69-85.
- Mohammaei, F. and Mohammadinasab, E. 2018.** Coefficient Partition Prediction of Saturated Monocarboxylic Acids Using the Molecular Descriptors. Journal of the Chilean Chemical Society, 63(3): 4068-4071.
- Nielsen, G.D. 2018.** Sensory irritation of vapours of formic, acetic, propionic and butyric acid. Regulatory Toxicology and Pharmacology, 99: 89-97.
- Polishchuk, P. 2017.** Interpretation of Quantitative Structure–Activity Relationship Models: Past, Present, and Future. J. Chemical Information Model, 57: 2618-2639.
- Qin, Z., Wang, M. and Yan, A. 2017.** QSAR studies of the bioactivity of hepatitis C virus (HCV) NS3/4A protease inhibitors by multiple linear regression (MLR) and support vector machine (SVM). Bioorganic & medicinal chemistry letters, 27(13): 2931-2938.
- Randic, M. and Basak, S. C. 2000.** Multiple regression analysis with optimal molecular descriptors. SAR & QSAR Research, 11: 1-23.
- Roy, K. and Ambure, P. 2016.** The “double cross-validation” software tool for MLR QSAR model development. Chemometrics and Intelligent Laboratory Systems, 159: 108-126.
- Roy, K. and Mitra, I. 2011.** On Various Metrics Used for Validation of Predictive QSAR Models with Applications in Virtual Screening and Focused Library Design. Combinatorial Chemistry & High Throughput Scree, 14: 450-474.
- Slattery, W.J. and Morrison, G.R. 1995.** Relationship between soil solution aluminium and low molecular weight organic acids in a conservation cropping system. In Plant-Soil Interactions at Low pH: Principles and Management, 589-593.
- Strobel, B.W., Bernhoft, I. and Borggaard, O.K. 1999.** Low-molecular-weight aliphatic carboxylic acids in soil solutions under different vegetations determined by capillary zone electrophoresis. Plant and Soil, 212(2): 115-121.
- Tani, M., Higashi, T. and Nagatsuka, S. 1996.** Dynamics of low-molecular-weight aliphatic carboxylic acids (LACAs) in forest soils: II. Seasonal changes of LACAs in an andisol of Japan. Soil science and plant nutrition, 42(1): 175-186.
- Todeschini, R. and Consonni, V. 2000.** Handbook of Molecular Descriptors. Weinheim: Wiley-VCH.
- Todeschini, R. and Consonni, V. 2009.** Molecular descriptors for chemoinformatics. Alphabetical listing (2nd ed., Vol. 1). Weinheim: Wiley-VCH.
- Tuzun, B., Yavuz, S.C., Sabanci, N. and Saripinar, E. 2018.** 4D-QSAR Study of Some Pyrazole Pyridine Carboxylic Acid Derivatives By Electron Conformational-Genetic Algorithm Method. Current computer-aided drug design, 14(4): 370-384.
- U.S. National Library of Medicine:** (<http://chem.sis.nlm.nih.gov/chemidplus/>).
- Williams, P. L., James, R. C., Roberts. S. M. 2003.** Ph.D., Principles of Toxicology: Environmental and Industrial Applications, Second Edition. John Wiley & Sons, Inc.
WWW.sigma-aldrich.com
- Xu, X., Du, X., Zheng, M. and Xu, Z.Y. 2005.** Synthesis of Carboxylic Acid Chlorides from Bis (trichloromethyl) carbonate. Pesticides-shenyang-, 44(6): 265.

Prediction of LD₅₀ for carboxylic acid derivatives using multiple linear regression and artificial neural networks models

F. Mohammiae¹, E. Mohammadinab^{2*}

1. PHD student, Department of Chemistry, Arak Branch, Islamic Azad University, P.O. BOX 38135-567, Arak, Iran
2. Assistant Professor, Department of Chemistry, Arak Branch, Islamic Azad University, P.O. BOX 38135-567, Arak, Iran

In this research, Quantitative Structure–Activity Relationship (QSAR) study has been used for prediction of toxicity values of carboxylic acid derivatives. Firstly, the toxicity (LD₅₀) values of data set of studied compounds were taken from the scientific web book and the their structures were drawn with the Gauss view 05 program and optimized at Hartree–Fock level of theory and 3-21G basis set by Gaussian 09 software. Then the dragon software was used for the calculation of molecular descriptors. The unsuitable descriptors were deleted with the aid of the genetic algorithm (GA) and backward techniques, and the best descriptors were used for multiple linear regression (MLR) and artificial neural network (ANN) models. The prediction accuracy of the final model was discussed using the statistical parameters. Leave-one-out cross-validation and external test set of the predictive models demonstrated a high-quality correlation between the observed and predicted toxicity values of all, training, test and validation sets in GA-ANN method. The model by ANN algorithm due to the lower error and higher regression coefficients was clearly superior to those models by MLR algorithm. The proposed model may be useful for predicting log LD₅₀ of new compounds of similar class.

Key words: "Toxicity" ; "Multiple linear regression method" ; "Artificial neural network" ; "Carboxylic acid derivatives.

* Corresponding Author, E-mail: -mohammadinab@iau-arak.ac.ir
Received: 10 Mar. 2021 – Accepted: 2 May. 2021