

МЕТОДОЛОГІЯ ЗАСТОСУВАННЯ ОПОРНО-ВЕКТОРНИХ МАШИН ДЛЯ ВИПАДКУ НЕРОЗДІЛЬНИХ ДАНИХ

Галкін О.А.

Постановка проблеми. Зі збільшенням обсягів даних, що генеруються науковцями, постає гостра необхідність в швидких, точних та надійних алгоритмах для аналізу цих даних. Оскільки головною метою інтелектуального аналізу даних є виявлення закономірностей у даних, використання опорно-векторних машин є ефективним методом для забезпечення розуміння процесу генерації даних та отримання корисних прогнозів. Опорно-векторна машина (ОВМ) є алгоритмом навчання, що застосовується до вивчення класифікаційних та регресійних правил даних. Двома ключовими елементами у реалізації ОВМ є *методи математичного програмування та функції ядра*. Усі необхідні параметри знаходяться з розв'язку задачі квадратичного програмування з лінійними обмеженнями рівності та нерівності, а не шляхом розв'язання неопуклої оптимізаційної проблеми без обмежень.

Загалом, у даній статті проводиться детальний аналіз даних для випадку, коли у класах відсутні будь-які шуми. У свою чергу, внеском у розробку теоретичної основи є формальний опис та узагальнення проблеми для випадку нероздільних даних. У такій ситуації, дані знаходяться під дією шумів, тому нашою задачею є побудова такого класифікатора, який би використовував принцип ігнорування певних визначених точок, які неправильно класифікуються у навчанні.

Ми зосередимося на ОВМ для двокласової класифікації, де класами будуть A та B для $y_i = +1, -1$, відповідно. Така класифікація може бути легко розширена для випадку k -класової класифікації, будуючи при цьому k двокласових класифікатори [1-3].

Максимальне поле гіперплощини. Якщо навчальні дані є лінійно роздільними, тоді існує пара (w, b) така, що:

$$\begin{aligned} w^T x_i + b &\geq 1, x_i \in A \\ w^T x_i + b &\leq -1, x_i \in B, \end{aligned} \quad (1)$$

де розв'язок знаходиться за наступним правилом:

$$f_{w,b}(x) = \text{sgn}(w^T x + b) \quad (2)$$

w називається *вектором ваги*, а b - *зміщенням* ($-b$ є *порогом*) [1]. Обмеження-нерівності (1) можуть бути об'єднані наступним чином:

$$y_i (w^T x_i + b) \geq 1, x_i \in A \cup B \quad (3)$$

Дотримуючись загальності, пара (w, b) може бути розрахована так, що:

$$\min_{i=1, \dots, l} |w^T x_i + b| = 1,$$

де дане обмеження визначає множину канонічних гіперплощин в \mathcal{R}^N .

Для того, щоб обмежити виразність простору гіпотез, ОВМ здійснює пошук найпростішого розв'язку, що коректно класифікує дані. Отже, навчальна проблема формулюється наступним чином: мінімізувати $\|w\|^2 = w^T w$ при обмеженнях лінійної роздільності (3). Це еквівалентно максимізації нормалі до гіперплощини між опуклими оболонками двох класів. Дана відстань називається *полем*. Отже, оптимізаційна проблема є опуклою проблемою квадратичного програмування (КП):

$$\min_{w,b} \Phi(w) = \frac{1}{2} \|w\|^2 \quad (4)$$

$$y_i (w^T x_i + b) \geq 1, i = 1, \dots, l$$

Оскільки проблема має глобальний оптимум, це означає, що вона має багато локальних оптимумів у випадку навчання, наприклад уникнення нейронної мережі. Перевагою у цьому випадку є те, що параметри КП - обчислювача будуть впливати тільки на час навчання, а не на якість розв'язку. Ця проблема є розв'язною, але для того, щоб перейти до випадку нероздільності та нелінійності, доцільно розглянути двоїсту проблему. Функцією Лагранжа цієї проблеми є:

$$L(w, b, \Lambda) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \lambda_i [y_i (w^T x_i + b) - 1], \quad (5)$$

де $\Lambda = (\lambda_1, \dots, \lambda_l)^T$ є множниками Лагранжа, по одному для кожної точки даних. Розв'язок цієї задачі квадратичного програмування визначається максимізацією L по відношенню до $\Lambda \geq 0$ та мінімізацією по відношенню до w, b . Диференціюючи по відношенню до w та b , а також встановлюючи похідні рівними 0, отримаємо:

$$\frac{\partial L(w, b, \Lambda)}{\partial w} = w - \sum_{i=1}^l \lambda_i y_i x_i = 0$$

та

$$\frac{\partial L(w, b, \Lambda)}{\partial b} = - \sum_{i=1}^l \lambda_i y_i = 0 \quad (6)$$

Отже, оптимальний розв'язок задається формулою (2) з наступним вектором ваги:

$$w^* = \sum_{i=1}^l \lambda_i^* y_i x_i \quad (7)$$

Підставляючи (6) та (7) в (5), ми можемо записати наступний вираз:

$$F(\Lambda) = \sum_{i=1}^l \lambda_i - \frac{1}{2} \|w\|^2 = \sum_{i=1}^l \lambda_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \lambda_i \lambda_j y_i y_j x_i^T x_j, \quad (8)$$

який, записуючи у матричній формі, веде до наступної двоїстої задачі [1]:

$$\max F(\Lambda) = \Lambda^T I - \frac{1}{2} \Lambda^T D \Lambda$$

$$\Lambda \geq 0, \Lambda^T y = 0, \quad (9)$$

де $y = (y_1, \dots, y_l)^T$ та D є симетричною $l \times l$ матрицею з елементами $D_{ij} = y_i y_j x_i^T x_j$. Необхідно зауважити, що множники Лагранжа є ненульовими лише тоді, коли $y_i (w^T x_i + b) = 1$, вектори для яких називаються *опорними векторами*, оскільки вони знаходяться найближче до розділової гіперплощини. Оптимальна вага отримується за допомогою (7), а зміщення за допомогою наступної формули:

$$b^* = y_i - w^{*T} x_i, \quad (10)$$

для будь-якого опорного вектора x_i (хоча на практиці безпечніше працювати з усередненням по всіх опорних векторах). Функція рішення задається наступним чином:

$$f(x) = \text{sgn}\left(\sum_{i=1}^l y_i \lambda_i^* x^T x_i + b^*\right). \quad (11)$$

Отримання розв'язку часто є доволі рідкісним явищем, оскільки у розв'язку з'являються лише x_i з ненульовими множниками Лагранжа. Це є важливим тоді, коли необхідно класифікувати дані великого розміру, як це часто буває в практичних ситуаціях інтелектуального аналізу даних.

Нероздільні дані. До сих пір ми обмежувалися випадком, коли два класи позбавлені будь-яких шумів. У випадку зашумлених даних, форсування нульової помилки навчання призводить до слабкого узагальнення. Це тому, що навчальний класифікатор встановлює особливості шуму в навчальних даних [4-6]. Для того, щоб прийняти до уваги той факт, що деякі точки даних можуть бути неправильно класифіковані, введемо вектор слабких змінних $\Xi = (\xi_1, \dots, \xi_l)^T$, що вимірює кількість порушень на обмеженнях (3).

Проблема може бути записана у наступній формі:

$$\begin{aligned} \min_{w, b, \Xi} \Phi(w, b, \Xi) &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i^k \\ y_i (w^T \phi(x_i) + b) &\geq 1 - \xi_i, \xi_i \geq 0, i = 1, \dots, l, \end{aligned} \quad (12)$$

де C та k задаються заздалегідь. C є параметром регуляризації, який контролює компроміс між максимізацією поля та мінімізацією терміну навчальної помилки. Якщо значення C є занадто малим, тоді недостатня увага буде приділена встановленню підготовки даних. Якщо C є дуже великим, тоді алгоритм буде розсіювати дані. Завдяки статистичним властивостям оптимальної розділової гіперплощини, значення C може обиратися без необхідності контрольної перевірки множини. Якщо $k=0$, тоді другий доданок буде рахувати кількість навчальних помилок. В цьому випадку, оптимізаційна проблема є NP-повною. Найменше значення, для якого (12) є розв'язною, це $k=1$. Значення $k=2$ також використовується, хоча в такому випадку збільшується чутливість до викидів в даних. Якщо ми вибираємо $k=2$, тоді ми виконуємо регуляризацію найменших квадратів, тобто припускається, що шум в x є нормально розподіленим [7].

В зашумлених доменах важливо знайти надійний класифікатор, тому ми вибираємо $k=1$. Функцією Лагранжа для цієї проблеми є наступний вираз:

$$L(w, b, \Lambda, \Xi, \Gamma) = \frac{1}{2} \|w\|^2 + \sum_{i=1}^l \lambda_i [y_i (w^T \phi(x_i) + b) - 1 + \xi_i] - \sum_{i=1}^l \gamma_i \xi_i + C \sum_{i=1}^l \xi_i, \quad (13)$$

де $\Lambda = (\lambda_1, \dots, \lambda_l)^T$ та $\Gamma = (\gamma_1, \dots, \gamma_l)^T$ є множниками Лагранжа, що відповідають позитивності слабких змінних. Розв'язком цієї проблеми є сідлова точка функції Лагранжа, що знаходиться при мінімізації L по відношенню до w, Ξ та b , а також при максимізації по відношенню до $\Lambda \geq 0$ та $\Gamma \geq 0$. Диференціюючи по відношенню до w, b та Ξ і фіксуючи результати рівними нулю, ми отримуємо:

$$\begin{aligned} \frac{\partial L(w, b, \Lambda, \Xi, \Gamma)}{\partial w} &= w - \sum_{i=1}^l \lambda_i y_i \phi(x_i) = 0, \\ \frac{\partial L(w, b, \Lambda, \Xi, \Gamma)}{\partial b} &= - \sum_{i=1}^l \lambda_i y_i = 0, \end{aligned} \quad (14)$$

та

$$\frac{\partial L(w, b, \Lambda, \Xi, \Gamma)}{\partial \xi_i} = C - \lambda_i - \gamma_i = 0. \quad (15)$$

Оптимальна вага знаходиться наступним чином:

$$w^* = \sum_{i=1}^l \lambda_i y_i \phi(x_i) \quad (16)$$

Підставляючи (14), (15) та (16) в (13), ми отримуємо наступну двоїсту задачу:

$$\begin{aligned} \max F(\Lambda) &= \Lambda^T I - \frac{1}{2} \Lambda^T D \Lambda \\ 0 \leq \Lambda \leq C, \Lambda^T y &= 0, \end{aligned} \quad (17)$$

де $y = (y_1, \dots, y_l)^T$ та D є симетричною $l \times l$ матрицею з елементами $D_{ij} = y_i y_j K(x_i, x_j)$. Якщо для всіх опорних векторів $\lambda = C$, тоді розв'язок є нестійким, оскільки глобальний оптимум не є унікальним. У цьому випадку, оптимальне відхилення може обчислюватися шляхом апеляції до геометрії гіперплощини [8].

Таким чином, ОВМ навчає оптимальну розділову гіперплощину в деякому просторі ознак, за умови ігнорування визначених точок, які неправильно класифікуються у навчанні. Навчена гіперплощина, що є розширенням на підмножину навчальних даних, називається також опорним вектором. За рахунок використання відповідної функції ядра, ОВМ може навчати широкий спектр класифікаторів, в тому числі велику множину РБФ мереж та нейронних мереж. Гнучкість ядер не призводить до надмірної підгонки, оскільки простір гіперплощин, що розділяють дані з великим полем, має набагато менший об'єм, ніж простір всіх реалізованих гіперплощин.

Практичне застосування. Більша частина дослідницької діяльності в ОВМ пов'язана з зменшенням часу навчання, вибором параметрів та зменшенням розміру моделі. Практично всі існуючі алгоритми для ОВМ масштабуються як $O(l) - O(l^3)$ в числі навчальних прикладів [9-11].

Існує безліч інших критеріїв зупинки, які можуть використовуватися та повинні бути доступними в загальному призначені пакету ОВМ для інтелектуального аналізу даних. Вони включають в себе обмеження в часі навчання та відстеження передбачених помилок. Якщо передбачена помилка падає нижче заздалегідь заданої точки, або якщо вона не має тенденцію для зниження, тоді алгоритм може бути зупинений, оскільки знаходження глобального оптимуму буде непотрібним та затратним по часу. Для того, щоб відстежувати передбачену помилку, можна звернутися до статистичної теорії навчання, щоб забезпечити верхню границю на передбаченій помилці "перевірка без одного".

Теорема (Йоахім, 2000) Частота помилки "перевірка без одного" стабільної ОВМ на навчальній множині S , обмежена наступним чином:

$$\sum_{i=1}^l c(f_{S \setminus i}(x_i), y_i) \leq |\{i : (2\lambda_i R^2 + \xi_i) \geq 1\}|,$$

де $f_{S \setminus i}$ є розв'язком ОВМ, коли приклад i виключається з навчальної множини S , а R^2 є верхньою границею на $K(x_i, x_i), i = 1, \dots, l$.

Ця величина може бути обчислена з дуже низькими витратами з поточної множини множників Лагранжа Λ . Помилка "перевірка без одного" $\sum_{i=1}^l c(f_{S \setminus i}(x_i), y_i)$ є незміщеною оцінкою справжньої

помилки. Загалом, обчислення є досить дорогим, але за рахунок статистичних властивостей ОВМ, помилка може бути обмежена легко обчислювальною кількістю.

Первинні формулювання (4) та (12) призводять до необхідності дотримання обмеження рівності (6) та (14) при вирішенні двоїстої задачі. Простою поправкою до алгоритму є включення виразу $\frac{1}{2}b^2$ в первинних формулюваннях. Це позбавляє від необхідності дотримання обмеження

рівності, як вимоги, що похідна функції Лагранжа по відношенню до b є нулем, призводить до $b = \alpha^T y$, а матриця D в (9) та (17) має елементи, що визначаються, як $D_{ij} = y_i y_j (K(x_i, x_j) + 1)$. Розв'язок цієї проблеми квадратичного програмування призводить до продуктивності, що є майже ідентичною стандартному формулюванню на широкому діапазоні реальних множин даних.

Опорно-векторні машини можуть бути розширені до оцінки регресії, вводячи ε - нечутливу функцію втрат:

$$L^\varepsilon(x, y, f) = |y - f(x)|_\varepsilon^p = \max(0, |y - f(x)| - \varepsilon)^p,$$

де $p \in \{1, 2\}$. Ця функція втрат вважає помилками лише ті передбачення, які віддалені від навчальних даних на відстань більшу, ніж ε . Більш того, дана функція втрат дозволяє поняттю поля бути перенесеним на випадок регресії, зберігаючи всі корисні статистичні властивості. Регресія опорних векторів також призводить до задачі квадратичного програмування (КП).

Висновки. В статті детально представлена специфікація ОВМ для класифікації даних. Оскільки опорно-векторні машини мають дуже мало вільних параметрів, вони можуть бути оптимізовані за допомогою теорії узагальнення без необхідності окремої перевірки множини під час навчання. Крім того, було показано, що запропонований підхід перевершує існуючі методи на широкому спектрі реальних проблем. Опорно-векторні машини не мають можливості вирішити всі відкриті проблеми у досліджуваній області, але, як методи ядра та методи максимального поля, вони сприяють подальшому просуванню та являються важливим інструментом для інтелектуального аналізу даних.

ПЕРЕЛІК ПОСИЛАНЬ

1. Burbidge R. and Buxton B. An Introduction to Support Vector Machines for Data Mining / Computer Science Dep., UCL, 2001.
2. Campbell C. and Ying Y. Learning with Support Vector Machines / Morgan and Claypool, 2011.
3. Cristianini N. and Shawe-Taylor J. An Introduction to Support Vector Machines / Cambridge University Press, 2000.
4. Duda R. and Hart P. Pattern Classification and Scene Analysis / John Wiley & Sons, 1973.
5. Mitchell T. Machine Learning / McGraw-Hill International, 1997.
6. Breiman L., Friedman J.H., Olshen R.A., and Stone C.J. Classification and Regression Trees / Chapman & Hall, 1984.
7. Breiman L., Friedman J.H., Olshen R.A., and Stone C.J. / Classification and Regression Trees, Chapman & Hall, 1984.
8. Hsu C.-W and Lin C.-J. A simple decomposition method for support vector machines / To appear in Machine Learning, 2001.
9. Kecman V. Learning and Soft Computing / Support Vector Machines, Neural Networks, Fuzzy Logic Systems, the MIT Press, Cambridge, MA, 2001.
10. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain / Psychological Review, 65:386-408, 1959.
11. Vapnik V. Statistical Learning Theory / Wiley-Interscience, 1989.

РЕФЕРАТ

Галкін О.А. Методологія застосування опорно-векторних машин для випадку нероздільних даних. / Олександр Анатолійович Галкін // Вісник НТУ. - К.: НТУ – 2012. – Вип. 26.

В статті запропонована методологія використання опорно-векторних машин для задачі класифікації даних.

Об'єкт дослідження – алгоритм навчання опорно-векторних машин для забезпечення розуміння процесу генерації даних та отримання корисних прогнозів

Мета роботи – аналіз специфікації опорно-векторних машин для вирішення проблеми класифікації даних.

Метод дослідження – метод опорно-векторних машин.

Двома ключовими елементами у реалізації опорно-векторних машин є методи математичного програмування та функції ядра. У статті представлений формальний опис застосування максимального поля гіперплощини для випадку, коли навчальні дані є роздільними. Проведено узагальнення проблеми виявлення закономірностей у даних для випадку нероздільних даних. Визначена специфікація практичного застосування опорно-векторних машин з використанням помилки “перевірка без одного”. Встановлено, що опорно-векторна машина навчає оптимальну розділову гіперплощину в деякому просторі ознак за умови ігнорування визначених точок, які неправильно класифікуються у навчанні. За рахунок використання відповідної функції ядра, ОВМ може навчати широкий спектр класифікаторів, в тому числі велику множину РБФ мереж та нейронних мереж. Гнучкість ядер не призводить до надмірної підгонки, оскільки простір гіперплощин, що розділяють дані з великим полем, має набагато менший об'єм, ніж простір всіх реалізованих гіперплощин.

Результати статті можуть бути упродовжені в технології класифікації даних при наявності шумів.

Прогнозні припущення щодо розвитку об'єкта дослідження – пошук методу для визначення оптимального значення параметрів ядра опорно-векторних машин без побудови оцінок та границь.

КЛЮЧОВІ СЛОВА: ЯДРО, ОПОРНО-ВЕКТОРНА МАШИНА, ГІПЕРПЛОЩИНА, КЛАСИФІКАТОР.

ABSTRACT

Galkin O.A. Methodology of application of the support vector machines for the case of non-separable data. / Oleksandr Galkin // Visnyk NTU. – K.: NTU. – 2012. – Vol. 26.

The article proposed methodology of using support-vector machines for the problem of data classification.

Object of study – the learning algorithm of the support-vector machines to ensure understanding of the process of generating data and obtain useful predictions.

Purpose – Analysis of specification of the support-vector machines to solve the problem of data classification.

Method study - the method of the support-vector machines.

The two key elements in the implementation of the support-vector machines are the methods of mathematical programming and the kernel functions. The paper presents a formal description of the application of maximal field of a hyperplane for the case when the training data are separable. A generalization of the problem of patterns identifying in the data for the case of non-separable data is conducted. Specification of practical application of the support-vector machines with leave-one-out error is determined. It was found that the support-vector machine teaches the optimal separating hyperplane in some feature space subject to neglecting certain points that are incorrectly classified in the study. By using an appropriate kernel function, SVM can teach a wide range of classifiers, including a large set of RBF networks and neural networks. Flexibility of kernels does not lead to over-fitting, since the space of hyperplanes separating the data with a large field, has a much smaller volume than the space of all implemented hyperplane.

The results of the paper can be implemented in the technology of data classification in the presence of noise.

Forecast assumptions about the object of study - the search of a method to determine the optimal values of the kernel parameters of the support-vector machines without building estimates and bounds.

KEY WORDS: KERNEL, SUPPORT-VECTRO MACHINE, HYPERPLANE, CLASSIFIER.

РЕФЕРАТ

Галкин А.А. Методология применения опорно-векторных машин для случая неразделимых данных. / Александр Анатольевич Галкин // Вестник НТУ. - М.: НТУ - 2012. - Вып. 26.

В статье предложена методология использования опорно-векторных машин для задачи классификации данных.

Объект исследования - алгоритм обучения опорно-векторных машин для обеспечения понимания процесса генерации данных и получения полезных прогнозов.

Цель работы - анализ спецификации опорно-векторных машин для решения проблемы классификации данных.

Метод исследования - метод опорно-векторных машин.

Двумя ключевыми элементами в реализации опорно-векторных машин являются методы математического программирования и функции ядра. В статье представлено формальное описание применения максимального поля гиперплоскости для случая, когда учебные данные являются раздельными. Проведено обобщение проблемы выявления закономерностей в данных для случая неразделимых данных. Определена спецификация практического применения опорно-векторных машин с использованием ошибки "проверка без одного". Установлено, что опорно-векторная машина учит оптимальную разделительную гиперплоскость в некотором пространстве признаков при игнорировании определенных точек, которые неправильно классифицируются в обучении. За счет использования соответствующей функции ядра, ОВМ может обучать широкий спектр классификаторов, в том числе большое множество РБФ сетей и нейронных сетей. Гибкость ядер не приводит к чрезмерной подгонке, поскольку пространство гиперплоскостей, которые разделяют данные с большим полем, имеет гораздо меньший объем, чем пространство всех реализованных гиперплоскостей.

Результати статті можуть бути внедрені в технології класифікації даних при наявності шумів.

Прогнозні передположення о розвитку об'єкта дослідження - пошук методу для визначення оптимального значення параметрів ядра опорно-векторних машин без побудови оцінок і границь.

КЛЮЧЕВІ СЛОВА: ЯДРО, ОПОРНО-ВЕКТОРНА МАШИНА, ГІПЕРПЛОСКОСТЬ, КЛАСИФІКАТОР.

УДК 678.046:677.862.516

ВПЛИВ УФ-ОПРОМІНЕННЯ НА ГОРЮЧИСТЬ ТЕРМОПЛАСТИЧНИХ МАТЕРІАЛІВ, ЩО ВМІЩУЮТЬ НАПОВНЮВАЧІ-АНТИПІРЕНИ НЕОРГАНІЧНОЇ ПРИРОДИ

Гордієнко В.П., доктор хімічних наук
Мусяца О.Н., кандидат хімічних наук
Ковальова Г.М.

Вступ. Одним із недоліків декотрих великотонажних полімерів є їх горючість. При горінні виробів із полімерних матеріалів, як правило, виділяються токсичні продукти. Тому проблема одержання полімерних матеріалів пониженої горючості є найбільш актуальною у розвитку сучасного полімерного матеріалознавства. Уведення в полімери наповнювачів неорганічної природи – один із способів зниження горючості полімерних матеріалів [1,2]. Раніше було показано [3-5], що фториди декотрих металів і кристалогідрати декотрих солей є одними із перспективних наповнювачів-антипіренів неорганічної природи, які здатні понижувати горючість декотрих термопластичних матеріалів. Зміна молекулярної структури полімерів в процесі старіння і вплив УФ-опромінення може впливати на процес їх горіння [2], однак публікації на цю тему практично відсутні.

Мета роботи. Метою даної роботи є визначення впливу УФ-опромінення на горючість великотонажних термопластичних матеріалів, що вміщують наповнювачі-антипірени неорганічної природи. Дослідження передбачає не тільки досягнення теоретичних результатів, а і застосування отриманих даних у практиці будівництва із застосуванням термопластичних полімерів і композицій на їх основі.

Об'єкти дослідження. Як об'єкти дослідження застосували: поліетилен високої щільності (ПЕ) з молекулярною масою $9,5 \cdot 10^4$, ступіню кристалічності 54%, поліформальдегід (ПФА) з молекулярною масою $6,5 \cdot 10^4$, суспензійний полівінілхлорид (ПВХ) марки С-6359 М (ГОСТ - 14332-78) з молекулярною масою $1,2 \cdot 10^5$ і аліфатичний поліамід (П-66) з молекулярною масою $2,1 \cdot 10^4$.

У якості наповнювачів-антипіренів застосовувались: гідрофторид калію (KHF_2), фторид кальцію (CaF_2), кристалогідрати сульфату цинка ($\text{ZnSO}_4 \cdot 7\text{H}_2\text{O}$) і калій-хром-сульфату ($\text{KCr}(\text{SO}_4) \cdot 12\text{H}_2\text{O}$). Розмір часток наповнювачів < 1 мкм, концентрація 50 об. %.

Методи дослідження. Наповнювачі ретельно перемішувались із дисперсними порошками полімерів у шаровому млині. Зразки для дослідження уявляли собою пластинки довжиною 80 мм, шириною 6 мм, товщиною 3 мм, що отримувались методом гарячого пресування під тиском 35 МПа на протязі 20 хв. Для випробування відносної горючості полімерних матеріалів застосовувався метод визначення кисневого індексу (КІ) по ГОСТ - 12.1.044-89. УФ-опромінення досліджуваних полімерних матеріалів здійснювалось під впливом нефільтрованого випромінювання ртутно-кварцової лампи ДРТ-1000 у атмосфері повітря протягом 100 годин при температурі 303 ± 5 К і періодичному перегортуванні зразків, таким же чином, як і в роботі [6].

Результати дослідження та їх обговорення. В таблиці 1 наведені значення кисневих індексів горіння досліджуваних полімерів та їх композицій із наповнювачами-антипіренами до і після 100 годинного УФ-опромінення.

Аналізуючи значення КІ, що наведено в таблиці 1, необхідно відмітити, що УФ-опромінення у більшій або меншій степені приводить до пониження кисневого індексу горіння досліджуваних полімерів і їх композицій із наповнювачами-антипіренами. У даному випадку простежується стійка тенденція до підвищення горючості полімерів, навіть для тих, що вміщують наповнювачі-антипірени. Не дивлячись на відносно незначне пониження КІ після УФ-опромінення полімерних матеріалів протягом 100 годин, можна передбачити, що цей ефект при більш тривалому впливі опромінення на матеріали може підсилюватися. Таке припущення цілком виправдано, якщо розглядати