

9. Models of Business Process of enterprise, available at: <http://businessstudio.ru/procedures/models/> (access date January 10, 2014).

10. Forrester, J. (1971), *Osnovy kibernetiki predpriyatiya (industrialnaya dinamika)* [Fundamentals of cybernetics enterprises (industrial dynamics)], Progress, Moscow, Russia, 340 p.

11. Hendricks, K.B., Ivey, R., Singhal, V.R., Stratman, J.K. (2007), "The Impact of Enterprise Systems on Corporate Performance: A Study of ERP, SCM and CRM System Implementations", *Journal of Operations Management*, Volume 25, Issue 1, pp. 65–82.

12. Kibira, D.A., Jain, S., McLean, C.R (2009), "System Dynamics Modeling Framework for Sustainable Manufacturing": available at: <http://systemdynamics.org/conferences/2009/proceed/papers/P1285.pdf> (access date January 10, 2014).

13. Bass, F.M. (1969), "A new product growth model for consumer durables", *Management Science*, Vol. 15, pp. 215-227.

УДК 336.748.12(048.85):004.032.26

Новікова В.В.,  
к.е.н., асистент кафедри інформаційних систем і технологій  
Білоцерківський національний аграрний університет

## ПРОГНОЗУВАННЯ ІНФЛЯЦІЙНИХ ПРОЦЕСІВ НА ОСНОВІ АПАРАТУ НЕЙРОННИХ МЕРЕЖ

Novikova V.V.  
cand.sc.(econ.), assistant of the department  
of information systems and technology  
Bila Tserkva National Agrarian University

## FORECASTING OF INFLATIONARY PROCESSES ON THE BASIS OF NEURAL NETWORKS

**Постановка проблеми.** Інфляція є одним з індикаторів макроекономічної нестабільності та фактором, від якого значною мірою залежить соціально-економічний розвиток країни, тому контроль інфляції – це ключова проблема державної економічної політики [5].

Аналіз та прогнозування інфляції необхідні як для кількісної оцінки найважливіших вартісних макроекономічних параметрів, так і для розробки та застосування адекватного механізму впливу держави на інфляційні процеси. Недосконалість методів прогнозування інфляції призводить до суттєвих відхилень та помилок у формуванні бюджету та вирішенні багатьох інших завдань, що стоять перед суспільством [2].

Особливої актуальності прогнозування інфляції набуває під час розробки короткострокових прогнозів соціально-економічного розвитку, оскільки на їх основі формуються проекти державного бюджету, визначаються основні напрямки грошово-кредитної політики, а також заходи щодо забезпечення основних параметрів економічного розвитку.

**Аналіз останніх досліджень і публікацій.** Питання, пов'язані із проблемами управління інфляцією, широко висвітлюються у вітчизняній науковій літературі. Основна увага в наукових публікаціях приділяється виявленню причин та наслідків інфляції, обґрунтуванню моделей прогнозування та методів її регулювання. Серед вітчизняних дослідників інфляції слід відмітити: А. Гальчинського, В. Гейця [2], С. Дзюбика, Б. Кваснюка, М. Ковалюка, Т. Ковальчука, О. Мельника, В. Найдьонова, М. Савлука, А. Савченка, В. Степаненко та інших. Але, незважаючи на велику кількість наукових публікацій і певні досягнення в теорії та практиці управління інфляційним процесом, ця проблема продовжує залишатися предметом наукових досліджень.

**Постановка завдання.** Мета дослідження полягає в обґрунтуванні доцільності використання методів економіко-математичного моделювання для прогнозування інфляційних процесів.

**Виклад основного матеріалу дослідження.** Інфляція – це тривале зростання загального рівня цін, що відповідно є свідченням зниження купівельної спроможності грошей.

Основними негативними наслідками інфляції є падіння рівня життя населення. Найбільше страждають групи населення із фіксованим доходом – наприклад, особи, що отримують заробітну плату або ж соціальну допомогу від держави. Відбувається також погіршення очікувань щодо поліпшення макроекономічної ситуації в майбутньому, що призводить, зокрема, до зниження ділової активності (через інвестиційну складову) [4].

На сьогодні одним з найефективніших способів здійснення прогнозування макроекономічних параметрів є економіко-математичне моделювання, але процеси інфляції настільки багатофакторні, що нині ще не існує досконалого апарату для цього.

Найбільш перспективним кількісним методом прогнозування є використання нейронних мереж. Можна назвати багато переваг нейронних мереж перед іншими методами, а саме: нейронні мережі мають більш гнучку структуру, для зміни структури у рамках визначеної архітектури нейронної мережі достатньо регулювати кількість шарів та нейронів, додаткові переваги надає можливість зміни активаційної функції. Лише ці незначні перетворення надають можливість повністю змінити структуру мережі, що дозволить максимально пристосувати обрану архітектуру, яка розв'язується, і, в свою чергу, дозволить мінімізувати похибку навчання мережі (підвищити точність прогнозування) [3].

Для прогнозування інфляційних процесів пропонуємо використання математичних моделей на основі апарату штучних нейронних мереж (ШНМ), які включають в себе структурне моделювання та методи навчання, що базуються на розвинутій теорії нелінійного програмування.

Штучні нейронні мережі (ШНМ) – це математичні моделі, а також їх програмні або апаратні реалізації, побудовані за принципом організації й функціонування біологічних нейронних мереж – мереж нервових клітин живого організму (рис. 1).

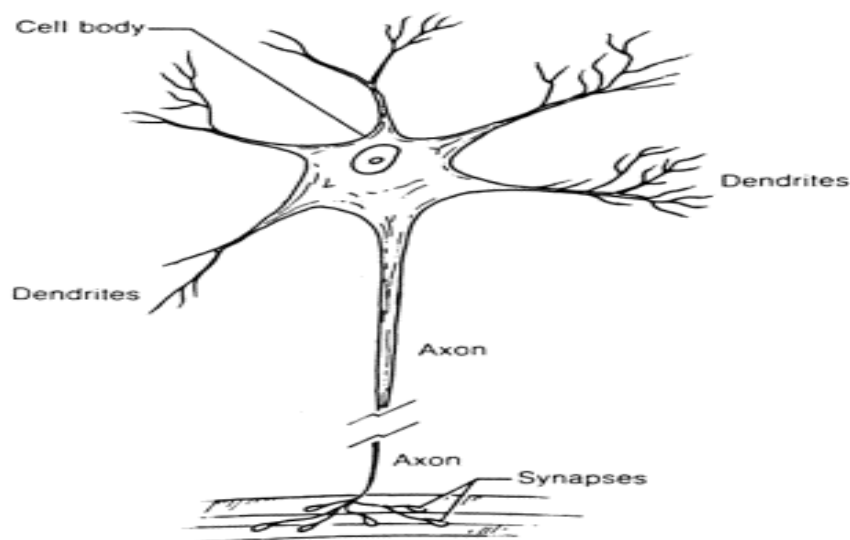


Рис. 1. Схема біологічного нейрона

Джерело: [8]

Нейронні мережі не програмується у звичному розумінні цього слова, вони навчаються. Можливість навчання – одна з головних переваг нейронних мереж перед традиційними алгоритмами [1].

Нейрон є складовою частиною нейронної мережі (рис. 2). Він складається з елементів трьох типів: помножувачів (синапсів), суматора та нелінійного перетворювача.




Рис. 2. Структура штучного нейрона

Джерело: [7]

Синапси здійснюють зв'язок між нейронами, множать вхідний сигнал на число, що характеризує силу зв'язку (вагу синапса).

Суматор виконує додавання сигналів, що надходять по синаптичних зв'язках від інших нейронів і зовнішніх вхідних сигналів.

Нелінійний перетворювач реалізує нелінійну функцію одного аргумента – виходів суматора. Ця функція називається функцією активації чи передатною функцією нейрона.

Математична модель штучного нейрона:

$$S = \sum_{i=1}^n w_i x_i + b, \quad (1)$$

$$y = f(s).$$

Існуючі на сьогодні нейромережі є групуванням штучних нейронів (рис. 3). Це групування обумовлено створенням з'єднаних між собою прошарків.

Більшість нейронних мереж містять як мінімум три нормальних типи прошарків – вхідний, прихований та вихідний.




Рис. 3. Діаграма простої нейронної мережі

Джерело: [8]

Прошарок вхідних нейронів отримує дані або з вхідних файлів, або безпосередньо з електронних давачів [1].

Вихідний прошарок пересилає інформацію безпосередньо до зовнішнього середовища, до вторинного комп'ютерного процесу, або до інших пристроїв.

Між цими двома прошарками може бути багато прихованих прошарків, які містять багато нейронів у різноманітних зв'язаних структурах. Входи та виходи кожного із прихованих нейронів просто йдуть до інших нейронів.

Оригінальність нейромереж, як аналога біологічного мозку, полягає у здібності до навчання за прикладами, що складають навчальну множину. Процес навчання нейромереж розглядається як налаштування архітектури та вагових коефіцієнтів синаптичних зв'язків відповідно до даних навчальної множини так, щоб ефективно вирішити поставлену задачу. Виділяють варіанти контрольованого та неконтрольованого навчання.

Розглянемо реалізацію однопараметричної та багатопараметричної задач прогнозування.

В однопараметричній задачі прогнозування нехай послідовність  $x(t)$  задано відліками процесу  $x(t_1), x(t_2), \dots, x(t_i)$  в дискретні моменти часу  $t$  (рис. 4). Задамо ширину (кількість дискретних відліків) вхідного часового вікна  $m$ , ширину вихідного вікна  $p$ . Вхідне та вихідне вікна накладаються на дані ряду, починаючи з першого елемента.




Рис. 4. Формування множин даних для однопараметричної задачі за методом "часових вікон"

Джерело: [6]

Вхідне вікно формує дані для входів нейронної мережі, а вихідне відповідно для виходів. Подібна пара вхідного та вихідного векторів приймається за одну реалізацію часового ряду. У разі зсуву часових вікон за часовим рядом із кроком  $s$  отримуємо другу і наступні реалізації [1].

Значення ширини вікон та кроку зміщення повинні узгоджуватись з особливостями часового ряду, що забезпечується шляхом проведення експериментів. Нехай вхідне вікно має ширину  $m$ , вихідне вікно  $p=1$ , крок зміщення  $s=1$ . Тоді сформована множина значень для однопараметричної задачі матиме вигляд таблиці 1.

Таблиця 1

Множина даних для однопараметричної задачі

Входи				Виходи
$x(t_1)$	$x(t_2)$	...	$x(t_m)$	$x(t_{m+1})$
$x(t_2)$	$x(t_3)$	...	$x(t_{m+1})$	$x(t_{m+2})$
$x(t_3)$	$x(t_4)$	...	$x(t_{m+2})$	$x(t_{m+3})$
...	...	...	...	...
$x(t_i)$	$x(t_{i+1})$	...	$x(t_{i+m-1})$	$x(t_{i+m})$

Джерело: [1]

У багатопараметричних задачах прогнозування підходи до розв'язання проблеми залишаються подібними (рис. 5).



**Рис. 5. Формування множин даних для багатопараметричної задачі**

Джерело: [1]

Нехай потрібно спрогнозувати взаємозалежні величини  $x(t)$ ,  $y(t)$ , ...,  $z(t)$ . Якщо прийняти ширину вхідного вікна  $m$ , вихідного  $p=1$ , кроку зміщення  $s=1$ , можна сформувати множину даних у вигляді таблиці 2.

**Таблиця 2**

**Множина даних для багатопараметричної задачі**

Входи								
$x(t_1)$	$x(t_2)$	$x(t_m)$	$y(t_1)$	$y(t_2)$	$y(t_m)$	$z(t_1)$	$z(t_2)$	$z(t_m)$
$x(t_2)$	$x(t_3)$	$x(t_{m+1})$	$y(t_2)$	$y(t_3)$	$y(t_{m+1})$	$z(t_2)$	$z(t_3)$	$z(t_{m+1})$
...	...	...	...	...	...	...	...	...
$x(t_i)$	$x(t_{i+1})$	$x(t_{i+m-1})$	$y(t_i)$	$y(t_{i+1})$	$y(t_{i+m-1})$	$z(t_i)$	$z(t_{i+1})$	$z(t_{i+m-1})$

Виходи		
$x(t_{m+1})$	$y(t_{m+1})$	$z(t_{m+1})$
$x(t_{m+2})$	$y(t_{m+2})$	$z(t_{m+2})$
...	...	...
$x(t_{i+m})$	$y(t_{i+m})$	$z(t_{i+m})$

Джерело: [1]

Функціонування нейромережі здійснюється у відповідності з показаним методом часових вікон, зберігаючи значення ширини вікон та кроку зсуву.

Конкретизація підходів до реалізації прогнозування значною мірою залежить також від особливостей явища, що досліджується.

Розглянемо однокрокове прогнозування (передбачення) та багатокрокове прогнозування.

У випадку однопараметричної задачі передбачення навчальна множина до моменту  $n$ , за умови  $m=3$ ,  $p=1$ ,  $s=1$ , матиме вигляд, наведений в таблиці 3.

Таблиця 3

Множина даних для однопараметричної задачі передбачення

Входи			Виходи
$x(t_1)$	$x(t_2)$	$x(t_3)$	$x(t_4)$
$x(t_2)$	$x(t_3)$	$x(t_4)$	$x(t_5)$
...	...	...	...
$x(t_{n-3})$	$x(t_{n-2})$	$x(t_{n-1})$	$x(t_n)$

Джерело: [1]

У режимі навчання встановлюються коефіцієнти ваг зв'язків, після чого стає можливим перехід до режиму функціонування. Для передбачення на входи нейромережі надходять значення останньої реалізації навчальної множини  $x(t_{n-2})$ ,  $x(t_{n-1})$ ,  $x(t_n)$ . На виході формується прогнозована величина  $x^*(t_{n+1})$ .

Для багатопараметричної задачі передбачення на входи навчальної нейромережі подаються вектори:  $x(t_{n-2})$ ,  $y(t_{n-2})$ ,  $z(t_{n-2})$ ,  $x(t_{n-1})$ ,  $y(t_{n-1})$ ,  $z(t_{n-1})$ ,  $x(t_n)$ ,  $y(t_n)$ ,  $z(t_n)$ . На виході нейромережі надходять передбачені величини  $x^*(t_{n+1})$ ,  $y^*(t_{n+1})$ ,  $z^*(t_{n+1})$ , які відкладаються у вихідний вектор передбачених даних.

Показаний режим є однокроковим, який працює в режимі відображення. Передбачення застосовують також для моделювання дискретних послідовностей, що не пов'язані з часом. Враховуючи специфіку часових рядів, такий тип прогнозу не завжди є доцільним, але для певних випадків короткотермінових прогнозів ним можливо скористатись [1].

Багатокрокове прогнозування застосовують лише для явищ, ознаки яких представлені у вигляді часових рядів.

Для однопараметричної задачі прогнозування навчальна множина матиме вигляд, наведений в табл. 3. Під час навчання мережа налаштовує коефіцієнти ваг зв'язків і поліномів передатних функцій, які надалі і визначають режим функціонування. Багатокрокове прогнозування часового ряду здійснюється наступним чином (рис. 6).

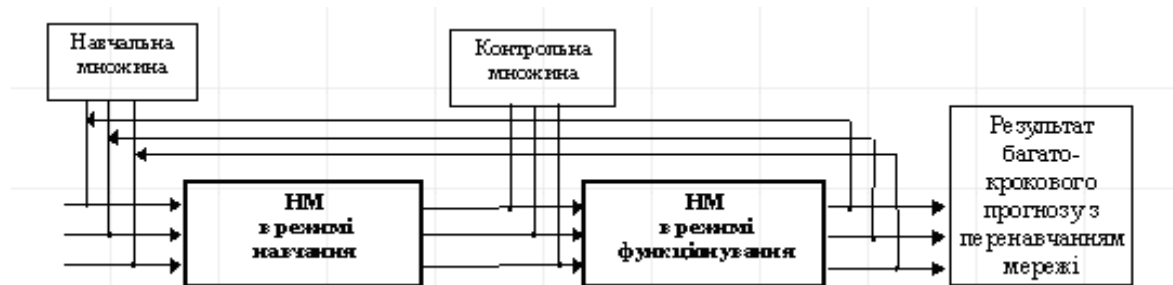


Рис. 6. Послідовність використання НМ для задач багатокрокового прогнозування

Джерело: [8]

На входи нейромережі подається вектор відомих значень  $x(t_{n-2})$ ,  $x(t_{n-1})$ ,  $x(t_n)$ . На виході формується прогнозована величина  $x^*(t_{n+1})$ , яка визначає вектор прогнозованих виходів і одночасно долучається до значень навчальної множини, тобто приймається як достовірна. Далі на входи подається вектор  $x(t_{n-1})$ ,  $x(t_n)$ ,  $x^*(t_{n+1})$ , а на виході отримується  $x^*(t_{n+2})$  і наступні прогнозовані значення.

Швидкі неітераційні алгоритми навчання дозволяють запропонувати новий тип багатокрокового прогнозу, який може бути застосований при довготермінових прогнозах зі збереженням задовільної точності прогнозування [3].

Аналогічно із попереднім алгоритмом прогнозування на входи мережі у режимі функціонування надходить остання реалізація навчальної множини  $x(t_{n-2})$ ,  $x(t_{n-1})$ ,  $x(t_n)$ . Прогнозоване значення виходу  $x^*(t_{n+1})$  відкладається у векторі прогнозованих вихідних значень і в якості достовірного додається до реальних значень навчальної множини. Навчальна множина збільшується на одне часове вікно. Відбувається процес перенавчання

мережі на збільшеній навчальній множині, під час якого визначаються нові вагові коефіцієнти к синаптичних зв'язків і поліномів передатних функцій нейронів.

Реалізація  $x(t_{n-1})$ ,  $x(t_n)$ ,  $x^*(t_{n+1})$ , як значення наступного вхідного вікна, подається на входи мережі в режимі функціонування. Мережа продукує нове вихідне значення  $x^*(t_{n+2})$ , яке відповідно також відкладається у вектор продукованих виходів і долучається до реальних значень навчальної множини з метою подальшого перенавчання мережі та встановлення поновлених коефіцієнтів поліномів передатних функцій і синаптичних зв'язків. Ітераційна процедура перенавчання поширюється до прогнозованого значення  $x^*(t_N)$ .

Такий підхід дозволяє при великих інтервалах випередження усунути затухання прогностичних властивостей мережі за рахунок постійного коректування вагових коефіцієнтів синаптичних зв'язків.

Як правило, після навчання нейромережі здійснюють контрольне відтворення даних, які склали навчальну множину. Якщо точність відтворення задовільна та відхилення знаходяться в допустимих межах, вважають, що побудовано задовільну модель і слід очікувати достатню якість відображення. Якщо при відтворенні мережею даних навчальної множини спостерігаються великі розбіжності, можна припустити, що це викликано:

- наявністю неточних даних з великою випадковою складовою. Для усунення цього явища підвищують вимоги до точності вимірювань; у випадку часового ряду можливе зменшення кроку дискретизації, наприклад використання щомісячних значень замість річних;
- неврахуванням суттєвих ознак, які значною мірою визначають закономірність, ця проблема може бути вирішена розширенням набору ознак, які беруться до уваги [1].

Після отримання передбачених значень за наявності правильних можливо отримати абсолютні та відносні відхилення на всій контрольній множині, для кожного кроку прогнозування. У разі наявності задовільних результатів прогнозування на контрольній множині, можна вважати, що налаштована мережа для цієї задачі має оптимальну складність і готова до відтворення даних, для яких немає відповідних відомих відгуків [3].

Використовуючи навіть найпростішу нейромережеву архітектуру (перцептрон з одним прихованим шаром) і базу даних (з інформацією про минулі події), для прогнозування інфляційних процесів легко одержати працюючу систему прогнозування. Причому буде система враховувати, чи не буде враховувати зовнішні параметри, визначатимуться включенням або виключенням відповідного входу до нейронної мережі [2].

**Висновки та подальші дослідження.** Застосування економіко-математичних моделей на основі штучних нейронних мереж для прогнозування інфляційних процесів дозволить передбачити зміну інфляції у майбутньому та допоможе виявити фактори, які будуть впливати на збільшення рівня інфляції, що дасть можливість регулювати не тільки інфляцію, але й інші макроекономічні процеси.

## Література

1. Боровиков В. Нейронные сети. Statistica neural networks: Методология и технологии современного анализа данных / В. Боровиков. – М. : Горячая линия – Телеком, 2008. – 392 с.
2. Моделі і методи соціально-економічного прогнозування: підручник / В.М. Геєць, Т.С. Клебанова, О.І. Черняк, В.В. Іванов, Н.А. Дубровіна, А.В. Ставицький. – Харків: ВД ІНЖЕК, 2005.– 396 с.
3. Глівенко С.В. Економічне прогнозування: навч. посіб. / С.В. Глівенко, М.О. Соколов, О.М. Теліженко – 3-тє вид., доп. – Суми: ВТД «Університетська книга», 2004. – 207 с.
4. Панчишин С.М. Макроекономіка: навч. посіб. / С.М. Панчишин – 3-тє, вид. – К. : Либідь, 2005. – 616 с.
5. Петрик О. І. Інфляція в Україні: проблеми, ризики, перспективи / О.І. Петрик // Вісник НБУ. – 2007. – № 3 – С. 2-8.
6. Руденко О.Г. Штучні нейронні мережі : навч. посібник. / О.Г. Руденко, Є.В.Бодяньський. – Харків: ТОВ “Компанія СМІТ”, 2006. – 404 с.
7. Тимошук П.В. Штучні нейронні мережі : навчальний посібник / П.В.Тимошук. – Львів: Видавництво Львівської політехніки, 2011. – 444 с.
8. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В.Круглов, В.В. Борисов. – М. : Горячая линия-Телеком, 2002. – 382 с.

## References

1. Borovikov, V. (2008), *Neyronnyie seti. Statistika neural networks: Metodologiya i tehnologii sovremennogo analiza dannyih* [Neural networks. Statistika neural networks: Methodology and the technologies of contemporary data analysis], Goryachaya liniya – Telekom, Moscow, Russia, 392 p.
2. Heets, V.M., Klebanova, T.S., Cherniak, O.I., Ivanov, V.V., Dubrovina, N.A., Stavtyskiy, A.V. (2005), *Modeli i metody sotsialno-ekonomichnoho prohnozuvannia* [Models and methods of socio-economic forecasting], tutorial, VD INZHEK, Kharkiv, Ukraine, 396 p.
3. Hlivenko, S.V., Sokolov, M.O. and Telizhenko, O.M. (2004), *Ekonomichne prohnozuvannia* [Economic forecasting], tutorial, VTD «Universytet-ska knyha», Sumy, Ukraine, 207 p.
4. Panchyshyn, S.M. (2005), *Makroekonomika* [Macroeconomics], tutorial, Lybid, Kyiv, Ukraine, 616 p.
5. Petryk, O.I. (2007), "Inflation in Ukraine: problems, risks, prospects", *Visnyk NBU*, no. 3, pp. 2-8.
6. Rudenko, O.H. and Bodianskiy Ye.V. (2006), *Shtuchni neironni merezhi* [Artificial neural networks], tutorial, TOV "Kompaniia SMIT", Kharkiv, Ukraine, 404 p.
7. Timoschuk, P.V. (2011), *Shtuchni neironni merezhi* [Artificial neural networks], tutorial, Vydavnytstvo Lvivskoi politekhniki, Lviv, Ukraine, 444 p.
8. Kruglov, V.V. and Borisov, V.V. (2002), *Iskusstvennyie neyronnyie seti. Teoriya i praktika* [Artificial neural networks. Theory and practice ], Goryachaya liniya-Telekom, Moscow, Russia, 382 p.

УДК 657.47:[658.15:671]

Попівняк Ю.М.,  
асистент кафедри обліку і аудиту  
Львівський національний університет імені Івана Франка

## МОДЕЛЬ ОПТИМІЗАЦІЇ ФУНКЦІОНУВАННЯ ОРГАНІЗАЦІЙНО-ФІНАНСОВОГО МЕХАНІЗМУ УПРАВЛІННЯ ВИТРАТАМИ ЮВЕЛІРНОГО ПІДПРИЄМСТВА

Popivniak Yu.M.,  
assistant of the department of accounting and auditing  
Ivan Franko National University of L'viv

## THE OPTIMIZATION MODEL OF THE ORGANIZATIONAL AND FINANCIAL FUNCTIONING MECHANISM FOR EXPENSES MANAGEMENT AT THE JEWELRY ENTERPRISE

**Постановка проблеми.** Сьогоднішній стан ювелірного ринку України характеризується як незадовільний, оскільки зумовлений наслідками світової фінансової кризи та поглиблений загальнодержавними проблемами і негативними чинниками діяльності вітчизняних ювелірних підприємств внутрішнього характеру. Так, функціонування в умовах збільшення цін на сировину, зниження платоспроможності та зростання вимогливості покупців, засилля імпортних виробів, відсутності держаної підтримки, нестабільності законодавчого регулювання та потреби у реструктуризації асортименту продукції спричинило різке падіння обсягів виробництва і реалізації, втрату зовнішніх ринків збуту та конкурентоспроможності вітчизняної продукції на внутрішньому ринку. Ключовим напрямом