

PREDIKSI MASA KEDALUWARSA WAFER DENGAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN PARAMETER NILAI KAPASITANSI

Prediction of Wafer Shelf Life using Artificial Neural Network based on Capacitance Parameter

Erna Rusliana Muhamad Saleh¹, Erliza Noor², Taufik Djatna², Irzaman³

¹Program Studi Teknologi Hasil Pertanian, Fakultas Pertanian, Universitas Khairun,
Jl. Raya Pertamina, Gambesi, Ternate 97716

²Departemen Teknologi Industri Pertanian, Fakultas Teknologi Pertanian, Institut Pertanian Bogor,
Kampus Institut Pertanian Bogor Darmaga Bogor 16680

³Departemen Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor,
Kampus Institut Pertanian Bogor Darmaga Bogor 16680
Email: ernaunkhair@yahoo.com

ABSTRAK

Wafer adalah jenis makanan kering yang sering ditemukan kedaluwarsa. Penentuan masa kedaluwarsa dengan observasi laboratorium memiliki beberapa kelemahan, diantaranya memakan waktu, panelis terlatih, suasana yang tepat, biaya dan alat uji yang kompleks. Alternatif solusinya adalah penggunaan Artificial Neural Network (ANN) berbasis parameter kapasitansi. Tujuan kerja ilmiah ini adalah untuk memprediksi masa kedaluwarsa wafer menggunakan ANN berbasis parameter kapasitansi. Algoritma pembelajaran yang digunakan adalah *Backpropagation* dengan *trial and error* variasi jumlah *node* per *hidden layer*, jumlah *hidden layer*, fungsi aktivasi, fungsi pembelajaran dan *epoch*. Hasil prediksi menunjukkan bahwa ANN hasil pelatihan yang dikombinasikan dengan parameter kapasitansi mampu memprediksi masa kedaluwarsa wafer dengan MSE terendah 0,01 dan R tertinggi 89,25%.

Kata kunci: Jaringan Syaraf Tiruan, masa kedaluwarsa, wafer, dielektrik, kapasitansi

ABSTRACT

Wafer is type of biscuit frequently found on expired condition in market, therefore prediction method should be implemented to avoid this condition. Apart from the prediction of shelf-life of wafer done by laboratory test, which were time-consuming, expensive, required trained panelists, complex equipment and suitable ambience, artificial neural network (ANN) based dielectric parameters was proposed in this study. The aim of study was to develop model to predict shelf-life employing ANN based capacitance parameter. Back propagation algorithm with trial and error was applied in variations of nodes per hidden layer, number of hidden layers, activation functions, the function of learnings and epochs. The result of study was the model was able to predict wafer shelf-life. The accuracy level was shown by low MSE value (0.01) and high coefficient correlation value (89.25%).

Keywords: Artificial Neural Network, shelf-life, wafer, dielectric, capacitance

PENDAHULUAN

Di antara sekian jenis makanan kering, wafer adalah makanan yang sering ditemukan dalam kondisi kedaluwarsa disamping coklat (BPOM, 2010). Kondisi ini akan semakin merugikan konsumen apabila kemasan wafer tidak mencantumkan masa kedaluwarsa atau masa kedaluwarsa yang tercantum palsu. Untuk itu, diperlukan pencantuman informasi kedaluwarsa yang akurat, cepat dan murah.

Metode memprediksi masa kedaluwarsa yang selama ini digunakan -ESS (*Extended Storage Studies*) dan ASLT (*Accelerated Self Life Testing*)- memiliki beberapa kelemahan. Diantara kelemahannya adalah membutuhkan waktu cukup lama (minimal 3-4 bulan), panelis terlatih, suasana yang tepat, biaya dan alat uji yang kompleks.

Selama beberapa dekade terakhir *Artificial Neural Network* (ANN) telah banyak digunakan secara luas. ANN adalah model matematika yang struktur dan fungsinya

terinspirasi oleh organisasi dan fungsi otak manusia (Bila dkk., 1999). Jaringan syaraf dapat menangani data nonlinier dan lebih toleran terhadap noise dari sistem, dan cenderung menghasilkan kesalahan prediksi yang rendah (Coulibaly, Bobe'e, dan Anctil (2001), Terra dan Tino's (2001); Siripatrawan dan Harte (2007); Siripatrawan, Linz, dan Harte, (2004)).

Di bidang penentuan masa kedaluwarsa, aplikasi ANN telah berhasil diterapkan untuk memprediksi masa kedaluwarsa kue susu coklat dihiasi dengan almond (Goyal dan Goyal, 2011a), Kalakand (Goyal dan Goyal, 2011b), susu putih dengan hiasan *pistachio* (Goyal dan Goyal, 2011c), keju (Goyal dan Goyal, 2012), *snack* dari beras (Siripatrawan dan Jantawat, 2008), tahu (Park dkk., 2002), susu kedelai (Ko dkk., 2000), dan produk susu (Cordoba dkk., 1995).

Pada kasus-kasus di atas metode ANN telah berhasil memprediksi sehingga dihasilkan hasil prediksi secara tepat. Hal ini karena, kemampuan ANN untuk mempelajari data historikal sehingga mampu memprediksi proses yang kompleks dari hubungan nonlinier yang ada antara data input (*casual process variable*) dan data output yang cocok (*dependent variables*).

Prediksi masa kedaluwarsa yang dilakukan oleh peneliti-peneliti sebelumnya berbasiskan parameter sifat non dielektrik (antara lain organoleptik, fisik, kimia, dan kondisi penyimpanan produk). Sementara penggunaan sifat dielektrik untuk memprediksi masa kedaluwarsa belum banyak dilakukan.

Sifat-sifat dielektrik produk pangan memiliki korelasi kuat dengan kadar air, yang merupakan parameter kritis kedaluwarsa produk kering. Nilai sifat dielektrik berbanding lurus dengan nilai kadar air suatu bahan. Pada kadar air yang tinggi, nilai tetapan dielektrik dan faktor kehilangan dielektrik juga tinggi, demikian juga pada kadar air rendah, nilai tetapan dielektrik dan faktor kehilangan dielektrik juga rendah (Harmen, 2001). Diantara sifat dielektrik yang terkait dengan kadar air adalah kapasitansi. Pengukuran nilai kapasitansi dapat dilakukan dalam waktu singkat dan tidak membutuhkan panelis sehingga dapat dilakukan dengan cepat dan biaya yang rendah.


Tujuan kerja ilmiah ini adalah untuk memprediksi masa kedaluwarsa wafer dengan ANN berdasarkan parameter kapasitansi. Prediksi dilakukan dengan model arsitektur ANN berkinerja terbaik.

METODE PENELITIAN

Pengukuran Nilai Dielektrik (Kapasitansi)

Pengukuran nilai kapasitansi dilakukan dengan LCR-meter HIOKI 3532-50 LCR HiTester (Gambar 1) yang telah

terhubung dengan komputer. Frekuensi pengukuran 42 Hz – 5MHz pada arus tetap (*Current Constant*) dengan 100 *point* pengamatan. Setiap wafer yang akan diukur, diset pada plat parallel berbahan tembaga, kemudian diukur nilai kapasitansi sebanyak 3 kali dan dirata-ratakan.



Gambar 1. Rangkaian alat pengukuran nilai dielektrik (kapasitansi)

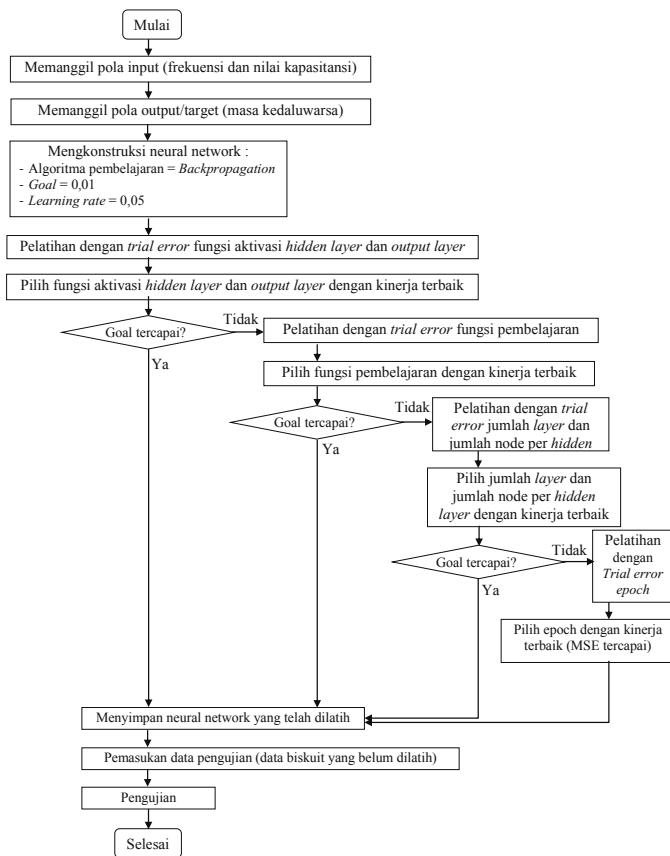
Kerangka Kerja Desain Arsitektur ANN

Untuk desain Arsitektur ANN digunakan kerangka kerja pada Gambar 2. Secara garis besar desain arsitektur terdiri dari lima tahap yaitu : pemanggilan data input dan target, pengkonstruksian neural network, pelatihan dengan *trial error* fungsi aktivasi, fungsi pembelajaran, jumlah *node* dan *hidden layer* dan *epoch*, pemasukan data pengujian dan pengujian. Ko dkk. (2000) dan Park dkk. (2002) telah mengembangkan sebuah mekanisme analisa neural network untuk memprediksi masa kedaluwarsa makanan. Gambar 3. memperlihatkan mekanisme analisa tersebut.

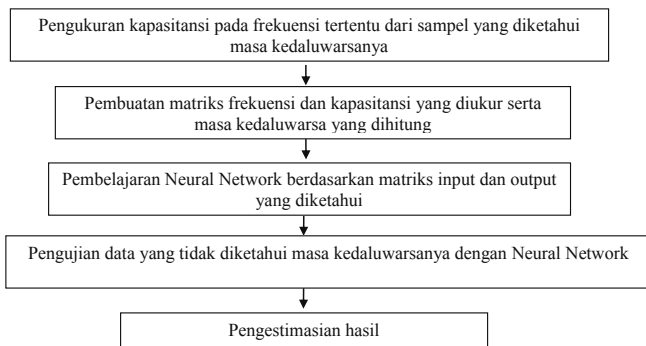
Dataset

Sampel yang diuji adalah wafer rasa coklat dalam kemasan aluminium foil yang diproduksi di Jakarta dan hampir selalu ada di setiap hypermarket, minimarket dan toko. Data aktual masa kedaluwarsa diambil dari tanggal kedaluwarsa yang tercantum pada kemasan dengan 10 jenis masa kedaluwarsa yang berbeda. Data ini diinputkan ke matriks ANN dengan menghitung durasi waktu dari tanggal saat pengukuran dengan tanggal kedaluwarsa yang tercantum di kemasan.


Data masukan adalah frekuensi dan kapasitansi, sedangkan data keluaran adalah masa kedaluwarsa aktual (Gambar 4). Jumlah data keseluruhan terdiri dari 1000 *dataset*. Sebanyak 80% data digunakan untuk pelatihan dan 20% untuk pengujian.



Gambar 2. Prosedur pemodelan ANN



Gambar 3. Mekanisme analisa neural network untuk memprediksi masa kedaluwarsa makanan (modifikasi dari Ko dkk. (2000) dan Park dkk. (2002))



Gambar 4. Arsitektur ANN untuk prediksi masa kedaluwarsa wafer

Praproses data. Sebelum dilakukan pemodelan ANN, data mentah dinormalisasi karena skala data yang berbeda. Proses normalisasi ditransformasi dengan formula berikut (Siang, 2009) :

$$x' = \frac{0.8(x - a)}{b - a} + 0.1 \dots\dots\dots (1)$$

dimana:

a = data minimum; b = data maksimum; x = data mentah; x' = data normalisasi

Desain model arsitektur ANN. Desain model arsitektur ANN dilakukan pada computer dengan CPU prosesor AMD dual-core C60 dan memori 2 GB DDR3. Software yang digunakan adalah MATLAB 2010b (Mathworks, 2011).

Algoritma pembelajaran yang digunakan adalah *backpropagation*. Arsitektur ANN *backpropagation* merupakan jaringan *perceptron* lapis jamak (*multilayer*). ANN ini memiliki lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*). Pembelajaran dalam *perceptron* terjadi dengan mengubah bobot koneksi setelah setiap elemen data diproses, yang diperoleh berdasarkan besarnya error dalam output (target) dibandingkan dengan hasil peramalan ANN. Proses ini dilakukan melalui *backpropagation*, yaitu sebuah generalisasi dari algoritma rata-rata kuadrat terkecil dalam *perceptron linear*.

Tabel 1. Modifikasi arsitektur ANN yang dilakukan

Fungsi aktifitas		Fungsi pembelajaran	Jumlah node/layer	Jumlah hidden layer	Epoch
Hidden layer	Output layer				
Tansig	Purelin	Trainglm	2	1	1000
	Tansig	Traingd	5	2	5000
	Logsig	Traingdm	10	3	
Logsig	Purelin	Traingda	15	4	
	Tansig	Traincgb	20	5	
	Logsig	Trainscg			
		Trainbfg			
		Traindx			
	Trainb				
	Trainbr				
	Trainoss				
	Trainrp				
	Trains				

Kinerja ANN ditentukan oleh tiga hal, yaitu pola hubungan antar neuron (arsitektur jaringan), metode untuk menentukan bobot penghubung (metode pelatihan, learning, algoritma), dan fungsi aktivasi. Kombinasi yang tepat dari ketiga hal tersebut akan menghasilkan kinerja ANN yang terbaik. Permasalahannya, sampai saat ini belum ada teori yang pasti terkait kombinasi parameter yang tepat untuk setiap kasus. Setiap kasus memiliki kombinasi parameter berbeda-beda, tergantung permasalahannya. Agar menghasilkan kinerja terbaik, perlu dilakukan *trial error* pada setiap parameter yang ada. Kombinasi parameter-parameter ini disebut arsitektur ANN. Tabel 1. memperlihatkan modifikasi parameter arsitektur yang dilakukan. Modifikasi Arsitektur ini menggunakan *goal* 0,01 dan *learning rate* 0,05.

Dengan mempertimbangkan keefektifan proses pelatihan, *trial error* dimulai dari fungsi aktivasi, kemudian secara berturut-turut diteruskan ke *trial error* fungsi pembelajaran, jumlah *node* dan *hidden layer* dan *epoch*. *Trial error* tahap berikutnya dilanjutkan jika belum mencapai MSE yang diharapkan. Tahap berikut di-*trial error* dengan menggunakan hasil terbaik parameter dari tahap sebelumnya. Jenis parameter fungsi aktivasi dan fungsi pembelajaran yang dikombinasikan diambil dari keseluruhan item parameter yang disediakan ANN pada MATLAB (*built in*). Dalam pemrograman *Backpropagation* dengan MATLAB, dikenal 3 macam fungsi aktivasi yang umum digunakan yaitu : *tansig* (fungsi *sigmoid bipolar*), *logsig* (fungsi *sigmoid unipolar*) dan *purelin* (fungsi identitas).

Jumlah *node* per *hidden layer* diawali dari 2 yang merupakan jumlah minimal *node* yang diproses ANN, kemudian berturut-turut dinaikan ke 5 sampai dengan 20. Jumlah *hidden layer* diawali dari 1 sampai dengan 5. Pada jumlah *hidden layer* 5, waktu proses telah cukup lama dan MSE yang dihasilkan telah mendekati MSE harapan, sehingga kinerja ditingkatkan dengan menambah *epoch* dari 1000 ke 5000.

Pemodelan prediksi masa kedaluwarsa wafer dengan metode ANN menggunakan analisa hasil observasi berbagai parameter untuk mendapatkan model ANN terbaik yang dapat merepresentasikan dengan akurat masa kedaluwarsa wafer tertentu. Model dianggap akurat jika kombinasi fungsi aktivasi per *layer*, jenis fungsi pembelajaran, jumlah *node* per *hidden layer* dan jumlah *hidden layer* memberikan MSE (*Mean Square Error*) terkecil dan R terbesar antara masa kedaluwarsa prediksi model ANN dengan masa kedaluwarsa sebenarnya.

Ukuran kinerja prediksi. Ukuran kinerja prediksi yang digunakan adalah R dan MSE.

$$R = \sqrt{1 - \left[\sum_1^N \left(\frac{Q_{exp} - Q_{cal}}{Q_{exp}} \right)^2 \right]} \dots\dots\dots (2)$$

$$MSE = \left[\sum_1^N \left(\frac{Q_{exp} - Q_{cal}}{n} \right)^2 \right] \dots\dots\dots (3)$$

Dimana :

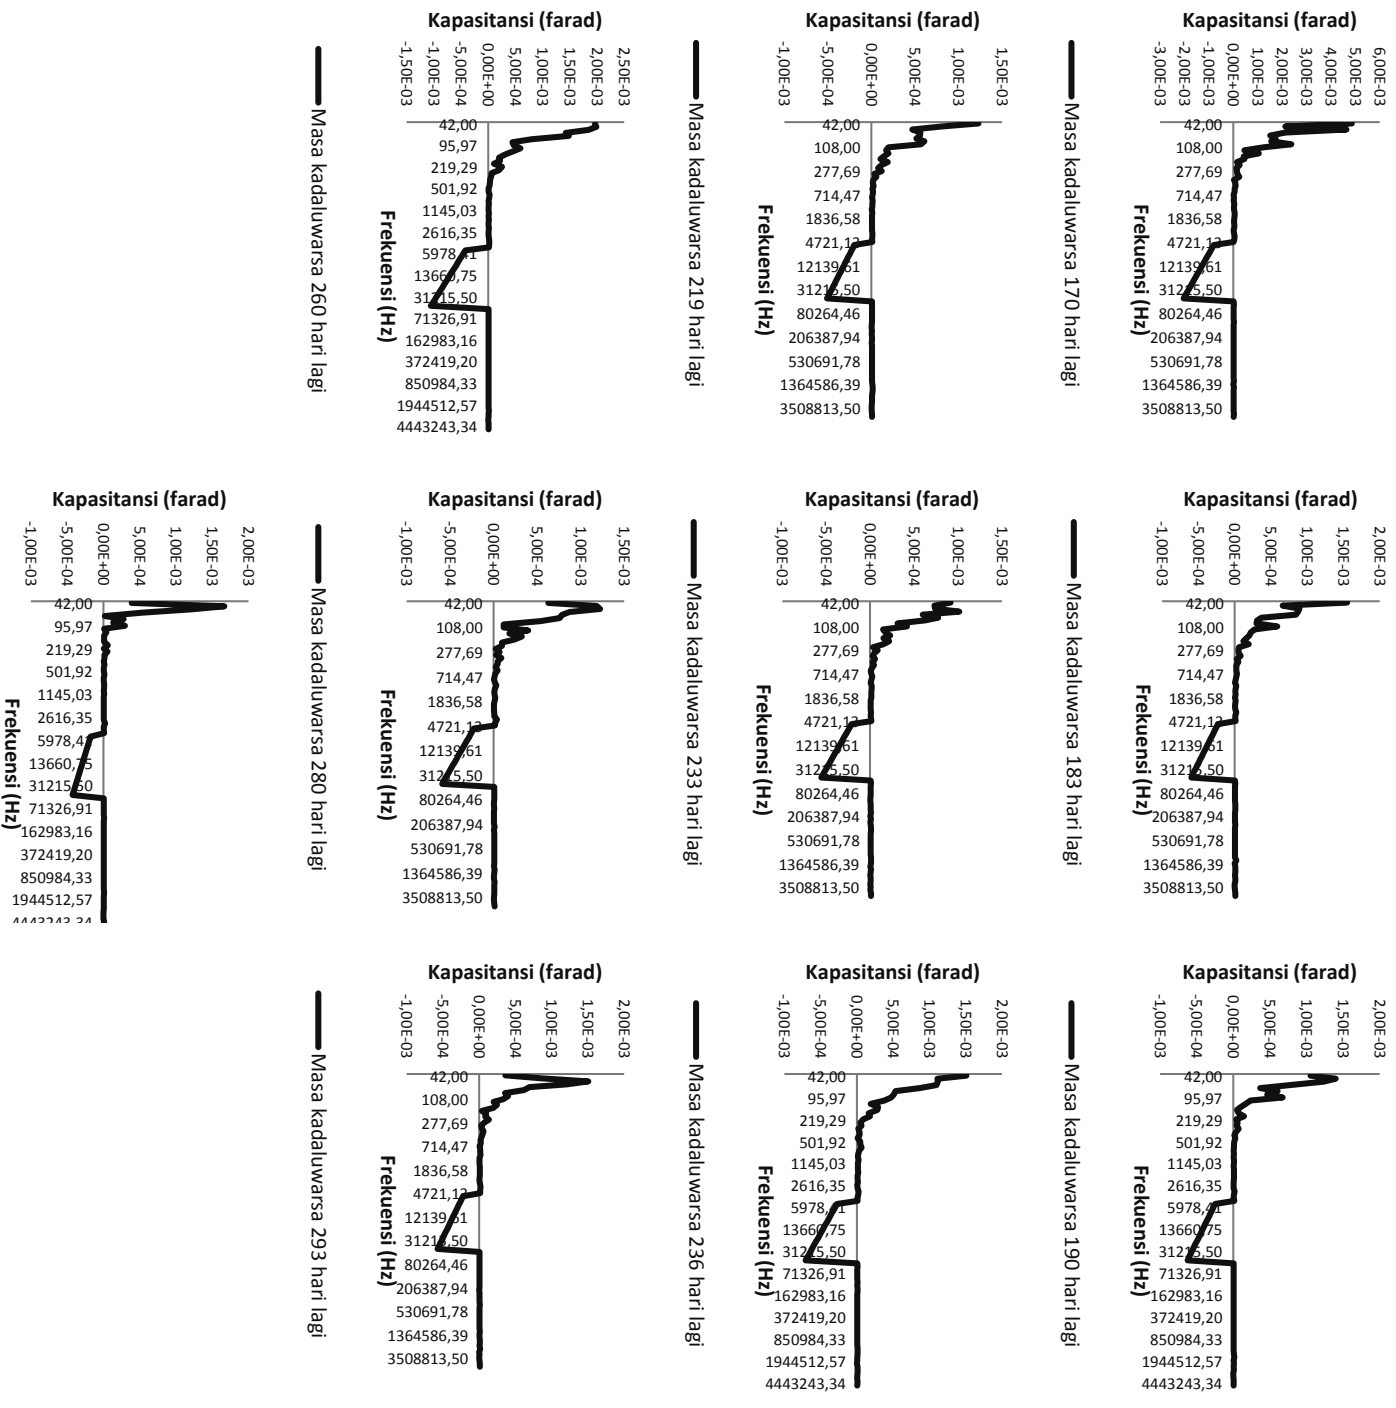
Q_{exp} = nilai pengukuran; *Q_{cal}* = nilai prediksi; *n* = jumlah *dataset* yang diukur.

HASIL DAN PEMBAHASAN

Nilai Dielektrik

Sifat dielektrik menggambarkan kemampuan suatu bahan untuk menyimpan, mentransmisikan dan memantulkan energi gelombang elektromagnetik. Aplikasinya dalam bidang pertanian didasarkan pada kemampuan bahan untuk menyerap radiasi elektromagnetik dan mengubahnya menjadi panas. Pada tingkat energi yang lebih rendah, sifat dielektrik dimanfaatkan untuk mengukur kadar air secara *non destruktif*. Nilai dielektrik yang diukur pada kasus ini adalah kapasitansi. Gambar 5. menunjukkan nilai kapasitansi wafer pada frekuensi 42 Hz-5 MHz untuk 10 masa kedaluwarsa yang berbeda.

Kapasitansi wafer dengan masa kedaluwarsa yang berbeda-beda diukur pada rentang frekuensi yang sama (42Hz-5MHz). Hasil pengukuran menunjukkan nilai kapasitansi cenderung berbeda-beda pada frekuensi wafer yang berbeda dengan masa kedaluwarsa berbeda. Hal ini sesuai dengan pendapat Nelson dan Trabelsi (2012) dan Sosa-Morales dkk. (2010) yang menyatakan bahwa frekuensi dan kadar air merupakan salah satu yang mempengaruhi nilai dielektrik (diantaranya kapasitansi). Sehingga nilai dielektrik setiap bahan akan berbeda-beda tergantung frekuensi pengukuran dan nilai kadar airnya. Kadar air merupakan variabel yang diketahui merupakan parameter kritis masa kedaluwarsa. Selain itu, pengukuran nilai kapasitansi merupakan satu paket dengan frekuensinya sehingga tidak dapat terpisahkan. Untuk mengukur nilai kapasitansi harus ditentukan pada range frekuensi berapa pengukuran dilakukan. Berdasarkan hal tersebut frekuensi dan kapasitansi dipertimbangkan sebagai variabel input dalam ANN dan masa kedaluwarsa adalah variabel output.



Gambar 5. Nilai kapasitansi wafer dengan 10 masa kadaluwarsa yang berbeda pada frekuensi 42Hz - 5MHz

Model Arsitektur ANN untuk Prediksi Masa Kedaluwarsa Wafer

Variasi fungsi aktivasi. Variasi fungsi aktivasi menghasilkan nilai MSE terkecil dan R terbesar pada fungsi aktivasi *hidden layer tansig* dan *output layer logsig* (Tabel 2.)

Tabel 2. Variasi fungsi aktivasi

Fungsi aktivasi		Fungsi train	MSE	R (%)
Hidden layer	Output layer			
Tansig	Logsig	Trainlm	0,0453	27,80
	Tansig		0,0461	24,75
	Purelin		0,0467	22,25
Logsig	Logsig		0,0460	25,08
	Tansig		0,0460	25,08
	Purelin		0,0459	25,61

Variasi fungsi pembelajaran. Hasil pelatihan dengan fungsi aktivasi di atas (*tansig; logsig*) menunjukkan fungsi pembelajaran dengan MSE terkecil dan R terbesar pada fungsi *Trainlm*.

Tabel 3. Variasi fungsi pembelajaran (*train*)

Fungsi pembelajaran (<i>train</i>)	MSE	R (%)
Trainlm	0,0453	27,80
Trainda	-	-
Traingdm	0,0583	-0,39
Traingd	0,0537	2,23
Traingdx	0,0483	13,33
Traincgb	0,0487	9,86
Trainscg	0,0463	23,83
Trainbfg	0,0469	22,21
Trainb	0,0520	2,42
Trainbr	0,0491	1,27
Trainoss	0,0474	18,99
Trainrp	0,0484	12,06
Trains	0,0540	-1,76

Variasi jumlah node dan hidden layer. Pada epoch ke 1000 dihasilkan jumlah node dan jumlah hidden layer terbaik adalah pada jumlah node 20 dengan 5 *hidden layer*. Terlihat semakin banyak layer dan jumlah node semakin bagus nilai R (88,07%) dan MSE (0,0110) (Tabel 4). Peningkatan nilai R dan MSE masih memungkinkan diperbaiki, akan tetapi berkonsekuensi pada waktu pelatihan yang semakin lama.

Tabel 4. Variasi jumlah node dan *hidden layer*


Jumlah node per hidden layer	Jumlah hidden layer									
	1		2		3		4		5	
	MSE	R (%)	MSE	R (%)	MSE	R (%)	MSE	R (%)	MSE	R (%)
2	0,0453	27,803	0,0444	30,97	0,0448	29,78	0,0464	23,79	0,0450	28,93
5	0,0426	36,57	0,0381	47,63	0,0365	50,91	0,0354	52,85	0,0355	52,73
10	0,0398	43,50	0,0360	51,64	0,0273	66,65	0,0235	72,23	0,0236	72,06
15	0,0404	42,11	0,0308	61,17	0,0241	71,49	0,0209	75,83	0,0129	85,90
20	0,0380	47,54	0,0287	64,65	0,0217	74,79	0,0150	83,41	0,0110	88,07

Variasi epoch. Peningkatan epoch dilakukan untuk memperbaiki nilai MSE dan R yang telah diperoleh pada tahapan sebelumnya (jumlah node 20; *hidden layer* 5; fungsi pembelajaran *trainlm*; fungsi aktivasi *tansig-logsig*). Tabel 5 menunjukkan epoch 2131 menghasilkan MSE terkecil dan

R terbesar. Pada tahapan ini goal 0,01 telah dicapai, namun waktu pelatihan yang diperlukan cukup lama 7 jam 59 menit 56 detik. Hubungan nilai prediksi masa kedaluwarsa aktual dan hasil prediksi ANN bernilai R 89,25% ditunjukkan pada Gambar 6.

Tabel 5. Variasi epoch


Epoch	MSE	R (%)	Goal
1000	0,0110	88,07	Belum tercapai
5000	0,0100	89,25	Tercapai pada 2131



Gambar 6. Kinerja pelatihan antara masa kadaluwarsa aktual dan hasil prediksi ANN dari 800 data latih

Prediksi Masa Kedaluwarsa dengan ANN

Sebanyak 200 *dataset* yang belum dicoba, diujikan pada arsitektur ANN yang terbaik hasil pelatihan sebelumnya. Hasil uji menunjukkan error sebesar 25,53%. Gambar 7. menunjukkan hasil prediksi data uji untuk masa kadaluwarsa wafer. Hasil prediksi menunjukkan nilai masa kadaluwarsa wafer berada pada 153,7511 hari (\approx 154 hari) - 316,25 hari (\approx 317 hari) sehingga terdapat selisih pada rentang $\epsilon^+ = 23,25$ dan $\epsilon^- = 146,2489$ dari data aktual. Data aktual masa kadaluwarsa yang diuji adalah 293 hari dan 300 hari.



Gambar 7. Kinerja pengujian (200 data uji) untuk masa kadaluwarsa wafer 293 dan 300 hari lagi

Selisih hasil prediksi ini (ϵ^+ dan ϵ^-) diduga dapat digunakan sebagai rentang toleransi masa kadaluwarsa wafer dari nilai aktual yang terdapat dalam kemasan. Dalam kasus ini, terdapat toleransi masa kadaluwarsa sebanyak +23,25 (\approx 24) hari dan -146,2489 (\approx 147) hari dari nilai aktual di kemasan. Namun hal ini bersifat dinamis, yang masih mungkin berkembang dengan studi-studi selanjutnya.

KESIMPULAN DAN SARAN

Kesimpulan

ANN yang dikombinasikan dengan parameter dielektrik (kapasitansi) sangat baik untuk memprediksi masa kadaluwarsa wafer dengan kinerja pelatihan MSE 0,01 dan R 89,25%. Arsitektur yang menghasilkan kinerja terbaik adalah ANN dengan 5 hidden layer, 20 node per hidden layer, fungsi aktivasi hidden layer *tansig*, fungsi aktivasi output layer *logsig.*, fungsi pembelajaran *trainlm* dan 2131 epoch.

Saran

Proses pembelajaran secara paralel dari semua parameter desain arsitektur ANN dapat dicoba untuk mendapatkan kinerja yang lebih akurat (MSE < 0,01 dan R > 99%) dengan waktu lebih singkat. Perbaikan kinerja ANN dapat dicobakan juga untuk jumlah node dan hidden layer yang lebih banyak dengan goal yang lebih kecil (<0,01).

DAFTAR PUSTAKA

BPOM (2010). Audit BPOM: Makanan Kedaluwarsa Mayoritas Jenis Biskuit, Coklat dan Permen. <http://www.detiknews.com/read/2010/09/05/095925/1435192/10/makanan-kedaluwarsa-mayoritas-jenis-biskuit-coklat-permen>. [7 Januari 2012].

Bila, S., Harkouss, Y., Ibrahim, M., Rousset, J., N’Goya, E., Baillargeat, D., Verdeyme, S., Aubourg, M. dan Guillon, P. (1999). An accurate wavelet neural-network-based model for electromagnetic optimization of microwave circuits. *International Journal of RF and Microwave Computer-Aided Engineering* **9**3: 297-306.

Cordoba B.V., Arteaga, G.E. dan Nakai, S. (1995). Predicting milk shelf-life based on artificial neural networks and headspace gas chromatographic data. *Journal of Food Science* **60**(5): 885–888.

Coulibaly, P., Bobe’e, B. dan Anctil, F. (2001). Improving extreme hydrologic events forecasting using a new criterion for artificial neural network selection. *Hydrocarbon Processing* **15**:1533-1536.

Goyal S. dan Goyal, G.K. (2011a). Radial basis artificial neural network computer engineering approach for predicting shelf life of brown milk cakes decorated with almonds. *International Journal of Latest Trends in Computing* **2**3: 434-438.

Goyal S. dan Goyal, G.K. (2011b). Advanced computing research on cascade single and double hidden layers for detecting shelf life of kalakand: an artificial neural network approach. *International Journal of Computer Science and Emerging Technologies* **2**(5): 292-295.

- Goyal S. dan Goyal, G.K. (2011c). A new scientific approach of intelligent artificial neural network engineering for predicting shelf life of milky white dessert jeweled with pistachio. *International Journal of Scientific and Engineering Research* **2**(9): 1-4.
- Goyal S. dan Goyal, G.K. (2012). A novel method for shelf life detection of processed cheese using cascade single and multi layer artificial neural network computing models. *ARPN Journal of Systems and Software* **2**(2):79-83.
- Harmen (2001). *Rancang Bangun Alat dan Pengukuran Nilai Dielektrik pada Kisaran Frekuensi Radio*. Fakultas Teknologi Pertanian. Program Pascasarjana. Institut Pertanian Bogor, Bogor.
- Ko, S.H. Park, E.Y., Han, K.Y., Noh, B.S. dan Kim, S.K. (2000) Development of neural network analysis program to predict shelf-life of soymilk by using electronic nose. *Food Engineering Progress* **4**(3): 193-198.
- Mathworks (2011). MATLAB Release 2010b. <http://www.mathworks.com>. [5 Desember 2012].
- Nelson S.O. dan Trablesi, S. (2012). Factors influencing the dielectric properties of agricultural and food products. *Journal of Microwave Power and Electromagnetic Energy* **46**(2): 93-107.
- Park, E.Y., Noh, dan Ko, S.H. (2002). Prediction of self life for soybean curd by the electronic nose and artificial neural network system. *Food Science and Biotechnology* **11**(3): 245-251.
- Siripatrawan, U. dan Harte, B.R. (2007). Solid phase microextraction/gas chromatograph/mass spectrometer coupled with discriminant factor analysis and multilayer perceptron neural network for detection of *Escherichia coli*. *Analytica Chimica Acta* **581**: 63-70.
- Sitipatrawan, U. dan Jantawat, P. (2008). A novel method for shelf life prediction of packaged moisture sensitive snack using multilayer perception neural network. *Expert Systems With Applications* **34**(2): 1562-1567.
- Siang, J.J. (2009). Jaringan Syaraf Tiruan dan Pemrograman Menggunakan Matlab. Andi Offset, Yogyakarta.
- Siripatrawan, U., Linz, J. dan Harte, B.R. (2004). Rapid method for prediction of *Escherichia coli* numbers using an electronic sensor array and an artificial neural network. *Journal of Food Protection* **67**: 1604-1609
- Sosa-Morales, M.E., Valerio-Junco, L., López-Malo, A. dan García, H.S. (2010). Dielectric properties of foods: reported data in the 21st century and their potential applications. *LWT - Food Science and Technology* **43**: 1169-1179.
- Terra, M.H. dan Tino's, R. (2001). Fault detection and isolation in robotic manipulators via neural networks: a comparison among three architectures for residual analysis. *Journal of Robotic Systems* **18**: 357-374.